



UNIVERSIDADE ESTADUAL DE CAMPINAS  
Faculdade de Ciências Aplicadas



ADILSON JOSÉ SPOLIDORO

**INFLUÊNCIA DE FATORES EXTERNOS NA PROJEÇÃO DE  
DEMANDA DE VENDA DE PRODUTO ALIMENTÍCIO, BISCOITO  
MOLDADO DE CHOCOLATE**

**INFLUENCE OF EXTERNAL FACTORS ON THE PROJECTION OF  
DEMAND FOR THE SALE OF FOOD PRODUCTS, CHOCOLATE  
MOLDED COOKIE**

LIMEIRA  
2020



UNIVERSIDADE ESTADUAL DE CAMPINAS  
Faculdade de Ciências Aplicadas



ADILSON JOSÉ SPOLIDORO

**INFLUÊNCIA DE FATORES EXTERNOS NA PROJEÇÃO DE  
DEMANDA DE VENDA DE PRODUTO ALIMENTÍCIO, BISCOITO  
MOLDADO DE CHOCOLATE**

*Dissertação apresentada à Faculdade de Ciências Aplicadas da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Mestre em Engenharia de Produção e Manufatura na área de Pesquisa Operacional e Gestão de Processos.*

*Orientador:* Prof. Dr. Aníbal Tavares de Azevedo.

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO  
DEFENDIDA PELO ALUNO ADILSON SPOLIDORO, E ORIENTADA PELO  
PROF. DR. ANÍBAL TAVARES DE AZEVEDO

LIMEIRA  
2020

Ficha catalográfica  
Universidade Estadual de Campinas  
Biblioteca da Faculdade de Ciências Aplicadas  
Renata Eleuterio da Silva - CRB 8/9281

Sp65i Spolidoro, Adilson José, 1959-  
Influência de fatores externos na projeção de demanda de  
venda de produto alimentício, biscoito moldado de chocolate /  
Adilson José Spolidoro. – Limeira, SP : [s.n.], 2020.

Orientador: Anibal Tavares de Azevedo.  
Dissertação (mestrado) – Universidade Estadual de Campinas,  
Faculdade de Ciências Aplicadas.

1. Redes neurais (Computação). 2. Análise de regressão. 3.  
Previsão de vendas. 4. Alimentos. I. Azevedo, Anibal  
Tavares, 1977-. II. Universidade Estadual de Campinas. Faculdade  
de Ciências Aplicadas. III. Título.

Informações para Biblioteca Digital

**Título em outro idioma:** Influence of external factors on the projection of  
demand for the sale of food products, chocolate molded cookie **Palavras-**

**chave em inglês:**

Neural networks (Computer science)

Regression analysis

Sales forecasting

Food

**Área de concentração:** Pesquisa Operacional e Gestão  
de Processos **Titulação:** Mestre em Engenharia de

Produção e de Manufatura **Banca examinadora:**

Anibal Tavares de Azevedo [Orientador]

Leonardo Tomazeli Duarte

Olinto César Bassi de Araújo

**Data de defesa:** 30-06-2020

**Programa de Pós-Graduação:** Engenharia de Produção e de Manufatura

**Identificação e informações acadêmicas do(a) aluno(a)**

- ORCID do autor: <https://orcid.org/0000-0002-5961-3624>

Curriculo Lattes do autor: <http://lattes.cnpq.br/5754516708348393>

## **Folha de Aprovação**

**Autor:** Adilson José Spolidoro

**Título:** INFLUÊNCIA DE FATORES EXTERNOS NA PROJEÇÃO DE DEMANDA DE VENDA DE PRODUTO ALIMENTÍCIO, BISCOITO MOLDADO MOLDADO DE CHOCOLATE

**Natureza:** Dissertação

**Área de Concentração:** Pesquisa Operacional e Gestão de Processos

**Instituição:** Faculdade de Ciências Aplicadas – FCA/Unicamp

**Data da Defesa:** Limeira-SP, 30 de junho de 2020.

### **BANCA EXAMINADORA:**

Prof. Dr. Anibal Tavares de Azevedo (orientador)  
Faculdade de Ciências Aplicadas - FCA/Unicamp

Prof. Dr. Leonardo Tomazeli Duarte (membro)  
Faculdade de Ciências Aplicadas - FCA/Unicamp

Prof. Dr. Olinto César Bassi de Araujo (membro externo)  
Universidade Federal de Santa Maria

A Ata de Defesa com as respectivas assinaturas dos membros da banca examinadora encontra-se no processo de vida acadêmica do aluno(a)

## DEDICATÓRIA

Esse trabalho é dedicado aos meus pais *Fioravante Spolidoro* e *Lurdes Marchini Spolidoro* que com muito trabalho e sacrifício permitiram que eu concluísse a Universidade, a minha querida esposa *Maria Gicene Dantas*, grande companheira nesta caminhada da vida e aos meus amados filhos *Leonardo Dantas Spolidoro* e sua esposa *Carolina Sorilla*.

*Aos 30 de junho de 2020.*

## AGRADECIMENTOS

Agradeço a toda ajuda, colaboração, paciência e incentivo de todo o corpo docente da FCA Limeira com os quais tive oportunidade de conviver, aprender e também aos companheiros de curso, muitos dos quais tornaram-se grandes amigos.

Aos professores Cristiano Torezan e Leonardo Tomazeli Duarte que sempre me incentivaram, ensinaram e deram orientações para que esse trabalho pudesse ser concluído.

Ao professor Francisco Ignácio Giocondo Cesar pelas inúmeras orientações e constantes incentivos pessoais.

À professora Ieda Kanashiro Makiya sempre me incentivando a prosseguir nesta jornada.

Um agradecimento muito especial para meu orientador prof. Anibal Tavares, ensinando sempre com muita paciência e resignação, constantemente me motivando durante essa jornada de aprendizagem e pesquisa.

## EPÍGRAFE

*“não que, por nós mesmos, sejamos capazes de pensar alguma coisa, como se partisse de nós; pelo contrario, a nossa suficiência vem de Deus”*

*2 Coríntios 3:5*

## RESUMO

Este trabalho tem por objetivo desenvolver um modelo de previsão do volume de venda de produtos alimentícios, considerando alguns fatores que influenciam a demanda. A forte concorrência do setor impõe a busca constante de produtividade e redução de custo por parte das indústrias. A busca por métodos que auxiliem na previsão das vendas é um fator preponderante para uma melhor eficiência operacional do planejamento da produção. Ter o conhecimento antecipado do volume a ser vendido por meio de uma projeção com menor erro possível é primordial para alcançar tal objetivo. A revisão bibliográfica mostrou, porém, poucos estudos específicos sobre previsão de vendas de produtos relacionados com o varejo. A partir de dados reais de venda, foi desenvolvido um modelo em Rede Neural Artificial (RNA) e de Regressão Linear (RL) de previsão do volume de venda correlacionando com variáveis independentes externas, tais como "preço", "investimento em mídia", "renda" e "Share" (participação de mercado). Um processo combinatório de uso das variáveis independentes nos modelos indicou a escolha de variáveis que possibilitou um menor erro percentual médio e um melhor coeficiente de correlação na amostra de treinamento. Os resultados mostraram que o modelo em RNA teve uma performance melhor que os modelo em RL, embora para algumas combinações a acurácia do modelo RL tenha sido próxima do modelo em RNA. Este estudo contribuiu no sentido de mostrar a influência desses fatores específicos na acurácia do resultado de previsão e forneceu um modelo de uso prático para previsão de outros tipos de produtos.

**Palavras-chave:** Redes neurais artificiais, regressão linear, previsão de venda de alimento, previsão de varejo.



## ABSTRACT

This work aims to develop a model for forecasting the volume of sale of food products, considering some factors that influence the demand. A strong competition from the sector imposes a constant search for reduction and cost reduction by the industries. The search for methods that assist in forecasting sales is a major factor for better operational efficiency in production planning. Having prior knowledge of the volume that is sold by means of a projection with the smallest possible error is essential to achieve the objective. The bibliographic review showed, however, few specific studies on forecasting sales of retail-related products. Based on real sales data, a model in Artificial Neural Network (RNA) and Linear Regression (RL) to predict sales volume correlated with external independent variables, such as "price", "media investment", "Income" and "Share" (market share) was developed. A combinatorial use process of the independent variables in the models indicated the choice of variables that allowed a lower average percentage error and a better correlation coefficient in the training sample. The results of the RNA model performed better than the model in RL, although for some combinations of accuracy the RL model was the next model of RNA. This study contributed to show the impact of these factors affected by the forecast result and provided a model of practical use for forecasting other types of products.

**Keywords:** Artificial neural networks, linear regression, food sales forecast, retail forecast.

## LISTA DE ILUSTRAÇÕES

Figura 1- A casa do SCM .....	20
Figura 2- O papel do gerenciamento da demanda dentro do gerenciamento da cadeia de suprimentos.....	22
Figura 3- Matriz de planejamento de suprimentos (SCM – Matrix) .....	22
Figura 4- Integração Vendas e Planejamento de Operações (S&OP) .....	24
Figura 5- Exemplos de padrões de séries temporais .....	26
Figura 6 - Modelos de previsão .....	27
Figura 7 - Modelo não-linear de um neurônio .....	37
Figura 8 - Exemplo de camada única alimentada para frente.....	40
Figura 9 - Exemplo de camadas múltiplas alimentadas para frente .....	41
Figura 10 - Exemplo de rede recorrente .....	42
Figura 11 - Exemplo de rede em malha.....	43
Figura 12- Modelo ilustrativo da estrutura de Rede neural MLP .....	44
Figura 13 - Análise Exploratória - Variável dependente - Volume de vendas (VOLUME).....	54
Figura 14 - Análise Exploratória - Variável dependente - volume faturado e de vendas do varejo ao cliente final .....	54
Figura 15- Análise Exploratória - Variável dependente - volume de vendas.....	56
Figura 16- Análise Exploratória - Variável independente – dispersão dos dados.....	57
Figura 17 - Linhas de tendência – Volume de vendas no período - análise exploratória dos dados.....	60
Figura 18 - Roteiro simplificado do código.....	64
Figura 19- Trajetória prevista comparativa demanda a partir dos dados de teste .....	73
Figura 20- Trajetória prevista comparativa demanda a partir dos dados de teste .....	74
Figura 21 - Volume previsto de 2020 a 2022 como resultado da simulação de cenário usando a “Série Polinomial decomposta de forma aditiva – DEPOAD”. .....	77
Figura 22- Volume previsto de 2020 a 2022 como resultado da simulação de cenário usando as séries DEPOAD e BASEORIGINAL.....	78
Figura 23– Comparativo entre as séries DEPOAD e BASEORIGINAL de volume previsto de 2020 a 2022 usando o cenário de simulação.....	79

## LISTA DE TABELAS

Tabela 1- Dados históricos.....	52
Tabela 2- Série de dados originais de volume de vendas .....	59
Tabela 3- Linha de tendência - série polinomial.....	60
Tabela 4 - Linha de tendência - série linear.....	60
Tabela 5 – Série polinomial decomposta de forma aditiva.....	65
Tabela 6 – Série polinomial decomposta de forma multiplicativa .....	65
Tabela 7- Série linear decomposta de forma aditiva .....	65
Tabela 8 - Série linear decomposta de forma multiplicativa .....	66
Tabela 9- Série indicadora de tendência de 2 períodos.....	66
Tabela 10 - Série indicadores de tendência de 3 períodos .....	67
Tabela 11 - Os melhores resultados de cada um dos modelos.....	69
Tabela 12- Os melhores resultados do modelo linear dentre os 10 melhores de cada série utilizadas.....	69
Tabela 13- Comparativo de desempenho médio dos indicadores de acurácia .....	70
Tabela 14- Os 10 melhores resultados usando a série de dados originais .....	70
Tabela 15- Os 10 melhores resultados usando a série polinomial decomposta de forma aditiva .....	71
Tabela 16- Os 10 melhores resultados usando a série polinomial decomposta de forma multiplicativa.....	71
Tabela 17- Os 10 melhores resultados usando a série linear decomposta de forma aditiva.....	71
Tabela 18- Os 10 melhores resultados usando a série linear decomposta de forma multiplicativa .....	72
Tabela 19- Os 10 melhores resultados usando a série com o indicador da diferença entre valor da série original e da média móvel de dois períodos .....	72
Tabela 20- Os 10 melhores resultados usando a série com o indicador da diferença entre valor da série original e da média móvel de três períodos .....	72
Tabela 21- Resultados da regressão realizada em Excel para cada uma das séries .....	74
Tabela 22- Premissas de cenário para simulação .....	75
Tabela 23 - Volume previsto para os anos 2020, 2021 e 2022 usando a série DEPOAD ...	77
Tabela 24- Volume previsto para os anos 2020, 2021 e 2022 usando a série BASEORIGINAL.....	78

## LISTA DE ABREVIATURAS E SIGLAS

**ABIA:** Associação Brasileira Da Indústria De Alimentos

**BASEORIGINAL:** Série Original

**DELIAD:** Série Linear decomposta de forma aditiva

**DELIMU:** Série Linear decomposta de forma multiplicativa

**DEPOAD:** Série Polinomial decomposta de forma aditiva

**DEPOMU:** Série Polinomial decomposta de forma multiplicativa

**DIFM2Série:** Indicador diferença 2 períodos média móvel

**DIFM3Série:** Indicador diferença 3 períodos média móvel

**FMTS:** *Fixed-Model time series* - Modelo fixo de série temporal

**MAE:** *Mean absolute error* - Error Médio

**MAPE:** *Mean Absolute Percentage Error* - Erro Médio percentual absoluto

**MLP:** *Multilayer Perceptron* - Perceptron Multicamadas

**MPE:** *Mean Percentage Error*- Erro Médio Percentual

**MSE:** *Mean squared error* - Erro Médio Quadrático

**OTMS:** *Open-model time series* - Modelo aberto de séries temporais

**RBF:** *Radial Basis Function* - Função de base radial

**RMSE:** *Root Mean Square Error* - Raiz Quadrada do erro médio quadrático

**S&OP:** *Sales and Operations Planning* - Planejamento de Vendas e Operações

**SC:** Supply Chain – Cadeia de suprimentos

**SCM:** *Supply Chain Management* - Gerenciamento da cadeia de suprimentos

**SCP - Matrix:** *Supply Chain Planning Matrix* - Matriz de planejamento da cadeia de suprimentos

# SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>14</b>
1.1 ORGANIZAÇÃO DA DISSERTAÇÃO .....	18
<b>2. FUNDAMENTO TEÓRICO .....</b>	<b>19</b>
2.1 GERENCIAMENTO DA DEMANDA .....	19
2.2 PREVISÃO DE VENDAS.....	23
2.3 SÉRIES TEMPORAIS – MODELOS DE PREVISÃO .....	31
2.3.1 <i>Suavização Exponencial – Holt – Winters</i> .....	32
2.3.2 <i>Regressão múltipla</i> .....	33
2.4. REDES NEURAIS ARTIFICIAIS.....	34
2.4.1 <i>Neurônio Artificial</i> .....	36
2.4.2 <i>Medidas de acurácia de previsão</i> .....	44
2.4.3 <i>Rede neural aplicada na previsão de demanda no setor de varejo de alimentos</i> .....	46
<b>3. METODOLOGIA .....</b>	<b>49</b>
3.1 MÉTODO - CONSIDERAÇÕES GERAIS .....	49
3.2 MÉTODO – DESCRIÇÃO DAS ETAPAS.....	50
3.2.1 <i>Dados</i> .....	51
3.2.2 <i>Análise Exploratória</i> .....	52
3.2.2.1 <i>Análise Exploratória –Variável Dependente</i> .....	53
3.2.2.2 <i>Análise Exploratória –Variáveis Independentes</i> .....	56
3.2.3 <i>Escolha do Modelo</i> .....	57
3.2.3.1 <i>Decomposição da Clássica</i> .....	58
3.2.3.2 <i>Modelo pela Rede Neural Artificial</i> .....	63
<b>4. RESULTADOS E DISCUSSÕES .....</b>	<b>68</b>
<b>5. CONSIDERAÇÕES FINAIS.....</b>	<b>80</b>
<b>6. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>84</b>
<b>APÊNDICES .....</b>	<b>89</b>

## 1. INTRODUÇÃO

O setor industrial de alimentos no Brasil processa 58% do que é produzido no campo através de 37 mil indústrias, empregando 1,6 milhão de empregos diretos, somente no ano de 2019 gerou 16 mil novos postos de trabalho. O setor exporta para 180 países, o que coloca o nosso país como o segundo maior exportador de alimentos industrializados do mundo. O faturamento total do setor representou 9,6% do PIB em 2019 e contribuiu com 67 % do saldo da balança comercial brasileira, contribuindo com um superávit de US\$ 28,8 bilhões (ABIA, 2019).

Dentro do setor, o segmento de biscoito representa um faturamento de R\$ 36,7 bilhões, suprindo o mercado com 3,33 milhões de toneladas, através de 47 fabricantes, com os mais variados tipos de biscoitos doces e salgados (ABIMAPI, 2019).

Dada a quantidade de empresas do segmento, há uma grande disputa entre os fabricantes para atrair a atenção do consumidor e sua ação para o ato final de compra. O resultado desse movimento irá definir o nível de lucratividade da empresa ou sua perda.

Neste ambiente, a formulação de uma estratégia competitiva analisando as forças de barganha dos fornecedores, dos novos entrantes do mercado, dos produtos substitutivos, dos consumidores e dos concorrentes torna-se fundamental para o resultado da empresa (PORTER, 1989). Portanto, o crescimento sustentado depende de uma visão mais abrangente do negócio e da avaliação constante das necessidades do consumidor (LEVITT, 2004).

A disponibilidade de produto nas prateleiras dos supermercados é a condição necessária para o consumidor finalizar seu ato de compra e a falta reduz o resultado financeiro do fornecedor, pois seu produto deixou de ser comprado devido a ruptura no estoque do ponto de venda.

O fenômeno da competição global, a enorme oferta de produtos

alimentícios, a velocidade de lançamentos de novos produtos, um maior número de manufaturas flexíveis, embora tenham beneficiado o consumidor em seu processo de escolha, tem imposto uma dificuldade maior de previsão de demanda dos produtos a serem vendidos e consequente dificuldade de planejamento do sistema produtivo (FISHER; HAMMOND, 1994).

Neste contexto competitivo, o atendimento da demanda para o consumidor final, exige um gerenciamento da cadeia de suprimentos de forma integrada onde todos os elementos desde o fornecedor inicial da matéria prima, fabricante, distribuidor e ponto de venda final, deve colaborar e coordenar ao longo de toda cadeia de valor, para converter matéria prima em produto acabado e entregá-lo ao consumidor final (IVANOV; TSIPOULANIDIS; SCHÖNBERGER, 2019).

O gerenciamento da cadeia de suprimentos, conhecida também com o termo SCM ("Supply Chain Management"), eleva a função da logística para a coordenação de fluxo de materiais, informações e financeiro tornando-se desafiadora e gratificante para a alta direção (STADTLER; KILGER; MEYR, 2015).

O SCM não é uma estratégia em si, mas é parte integral de uma estratégia corporativa, podendo atuar com foco nos recursos internos ou baseado em uma visão de mercado ou em ambas concomitantemente. Os recursos internos são os ativos, as capacidades, processos organizacionais, conhecimento do negócio, controlado pela empresa para conceber uma estratégia que melhore a eficiência e eficácia da organização (BARNEY, 1991).

Considerando o SCM sob uma visão de mercado, é necessário atuar contra as forças de competidores, potenciais entrantes, poder dos fornecedores e novos produtos substitutos (PORTER, 2008).

O SCM é muito complexo, centenas de decisões devem ser tomadas e coordenadas a cada minuto, com diferentes graus de importância do tipo "o que deve ser produzido, quanto e em que máquina?". Algumas ainda mais difíceis tais como se deve ou não fechar uma fábrica, construir ou não um novo centro de distribuição. Estar preparado com um planejamento é crucial para enfrentar todas as inúmeras

decisões que devem ser tomadas no dia a dia da organização.

Este planejamento pode ser dividido nas seguintes fases (STADTLER, 2005):

- . Definição de objetivos;
- . Previsão de desenvolvimento futuro;
- . Identificação de soluções viáveis;
- . Seleção das boas soluções.

Pelo fato que um plano não ser permanente, sua validade é restrita a um período de tempo. As decisões por ser classificadas em três diferentes níveis de planejamento (ANTHONY, 1965):

- . Longo prazo, decisões a nível estratégico da cadeia de suprimentos;
- . Médio prazo, decisões de quantidades e fluxo da cadeia de suprimentos;
- . Curto prazo, detalhamento das decisões compreendendo o período de alguns dias até 3 meses.

Embora a execução de um planejamento seja um exercício de encontrar alternativas e compara-las, esse processo encontra algumas dificuldades (STADTLER; KILGER; MEYR, 2015):

- . Há diversos critérios de seleção de alternativas que implica em conflitos de objetivos.
- . Dificuldade causada pelo grande número de alternativas disponíveis em cadeias de suprimentos.
- . Lidar com a incerteza, dificuldade, possivelmente é a mais difícil.

Integrar as ações de planejamento nos diferentes níveis, sendo longo prazo, médio prazo e curto prazo, com os fluxos de processos de matérias e informações ao longo da cadeia de suprimentos é a ideia básica por trás do planejamento hierárquico (MILLER, 2002). Neste conceito no nível mais acima há o plano da empresa ao longo prazo, no nível intermediário as ações de programação de médio prazo e no nível mais inferior a execução das ações do plano de fabricação, distribuição e vendas. Dos níveis superiores para os níveis inferiores há uma



desagregação das informações que permitirá as ações diárias de planejamento.

A matriz de planejamento da cadeia de suprimentos ("SCP-Matrix") utiliza do conceito de planejamento hierárquico para classificar as ações de planejamento em duas dimensões "horizonte de planejamento" e "processo da cadeia de suprimentos". Dentre as inúmeras funções cobertas pela SCP-Matrix, a função de previsão de demanda, objeto do presente estudo, se enquadra como uma atividade de médio prazo dentro do processo do setor de vendas (MILLER, 2002).

Projetar a demanda futura é fundamental para o sucesso do negócio, para manter um alto nível de serviço com baixo custo de estoques ao longo da cadeia de suprimentos. Neste trabalho foi desenvolvido um modelo de previsão de demanda para um produto alimentício mais especificamente, biscoito moldado de chocolate, levando-se em consideração algumas informações pertinentes ao processo de venda, que são:

- . volume de venda;
- . preço de venda;
- . renda média disponível;
- . investimento em mídia;
- . participação de mercado deste produto no mercado total.

Também foi avaliado se o estudo pode ser replicável para outras categorias de alimentos, respeitando as características intrínsecas de cada mercado.

Dois modelos de projeção foram desenvolvidos, o primeiro usando uma Rede Neural e o segundo uma Regressão linear, com quatro variáveis combinadas a fim de saber qual seria a melhor combinação entre elas que proporcionaria o melhor resultado da correlação com o menor erro numa amostra escolhida aleatoriamente como conjunto de treinamento.

## 1.1 Organização da Dissertação

O trabalho foi desenvolvido através de pesquisa teórica sobre o tema de previsão de demanda realizada na seção 2, sua importância, dificuldades e restrições para as empresas. Os principais modelos tradicionais de projeção foram apresentados de forma resumida. Nesta etapa, enfatizamos os modelos de Redes Neurais e Regressão linear que foram os escolhidos para este estudo, onde a literatura mostra alguns casos de aplicação para o setor de varejo em bebidas, frutas e lácteos.

Na seção 2 também foi apresentada uma revisão sucinta da literatura sobre Redes Neurais e Regressão Linear, considerando casos aplicados no setor de alimentos. Uma pesquisa em base de dados foi realizada, para identificar trabalhos correlatos, que possam ter utilizado algumas das variáveis independentes que usamos em nosso modelo.

O método utilizado foi descrito na seção 3, onde desenvolvemos o processo de estruturação dos dados e elaboração do modelo de previsão. Introduziremos um indicador cujo objetivo é mostrar o sentido de crescimento do volume e a distância em relação à média móvel da variável dependente.

Resultados e discussões foram descritos na seção 4, comparando os resultados de cada modelo, a identificação da combinação de variáveis independentes que promovem uma melhor correlação e menor erro de previsão. Como este estudo teve como um dos objetivos ser replicável para outros tipos de produtos alimentícios, algumas sugestões para futuras pesquisas que emergem do presente trabalho no segmento de varejo alimentício foram delineadas na seção 5.

## **2. FUNDAMENTO TEÓRICO**

### **2.1 Gerenciamento da demanda**

O gerenciamento da demanda é a criação de um fluxo coordenado de demanda ao longo da cadeia de suprimentos nos mercados. Em geral a função de marketing é criar produtos, porém essas informações muitas vezes não fluem para outras funções na empresa ou para outras empresas participantes da cadeia de suprimentos. A participação dos parceiros na cadeia de suprimentos é fundamental para um resultado positivo do gerenciamento e identificar produtos que não contribuem positivamente para a lucratividade (MENTZER; MOON, 2005).

A cadeia de suprimentos é uma rede de organizações e processos compreendendo várias empresas (fornecedores, fabricantes, distribuidores e lojas de varejo), cooperando através de toda a cadeia para transformar matéria prima em produto acabado entregando para o consumidor final (IVANOV; TSIPOULANIDIS; SCHÖNBERGER, 2019).

O gerenciamento da cadeia tem vários aspectos, porém um dos quais é o gerenciamento da demanda propriamente dito (MENTZER; MOON, 2005). A falta de sincronismo entre os elementos da cadeia pode acarretar em um problema de falta ou excesso de produto, causando prejuízos e redução das margens de lucro (MELO; ALCÂNTARA, 2011).

Há inúmeras definições do termo SCM, mas podemos resumir a essência como sendo a tarefa de integrar as unidades organizacionais a cadeia de suprimentos (SC) e coordenar materiais, informações e fluxos financeiros no sentido de suprir a demanda do consumidor com intuito de melhorar a competitividade da SC como um todo (STADTLER, 2005). Esta definição pode ser visualizada na Figura 1.

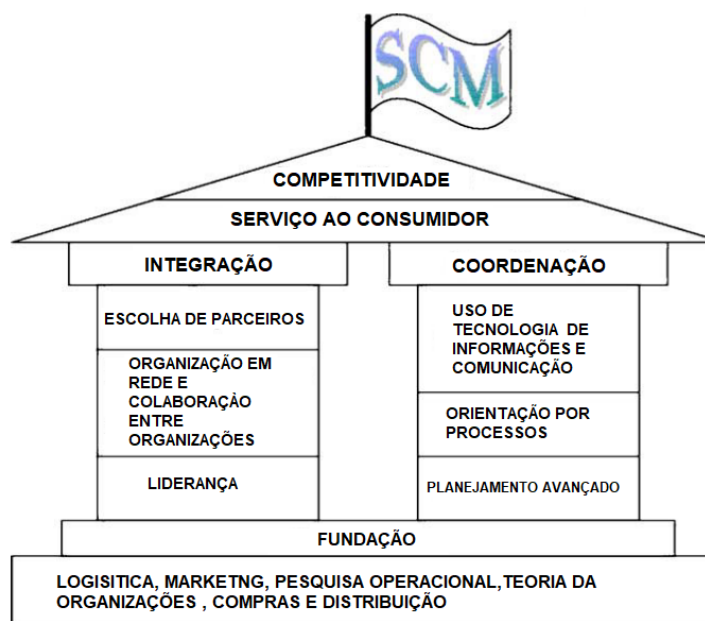


Figura 1- A casa do SCM

Fonte: (STADTLER, 2005).

A casa SCM é composta por:

- . Teto – melhorar a competitividade da SC como um todo, suportado por integração das unidades organizacionais e coordenação dos fluxos;
- . Escolha dos parceiros – que melhor se adequem as necessidades do consumidor;
- . Organização da rede de colaboração Interorganizacional;
- . Liderança – presença de um parceiro forte do ponto de vista financeiro ou tecnológico;
- . Uso de tecnologia de informação – permite a troca de informações instantaneamente com os parceiros da SC;
- . Orientado por processo – supera barreiras entre as funções de negócios e parceiros;
- . Planejamento avançado – sistema de planejamento baseado no princípio de hierarquia de planejamento.

Portanto, o SCM representa um novo foco em como conectar unidades organizacionais para servir melhor o consumidor e melhorar a produtividade da SC como um todo. Para tanto se utiliza de diversas disciplinas como a logística, ciência

da computação, marketing, pesquisa operacional, teoria das organizações e algumas outras (STADTLER, 2005).

A função do gerenciamento da demanda e previsão de vendas depende da posição e importância que ocupa na organização. Qualquer SC tem apenas um ponto de *demand independente*, que é a necessidade de produto direto do consumidor final. Um segundo tipo é *demand derivada*, que é o fornecimento de matérias primas ou peças solicitadas por outros integrantes da cadeia principal para atender seu consumidor imediato. A *demand dependente*, que não é para o consumidor final, é o fornecimento de componentes que fazem parte de um produto (MENTZER; MOON, 2005).

Um aspecto importante do gerenciamento da demanda é a relação com os elementos participantes da cadeia visando a busca de melhoria de performance e ganhos de produtividade para toda a cadeia em termos de redução de custo. O gerenciamento da cadeia de suprimentos tem vários aspectos, um dos quais é o gerenciamento da demanda, a Figura 2, mostra o papel desempenhado pelo gerenciamento e planejamento da demanda, bem como da previsão de venda (MENTZER; MOON, 2005).

Os vários aspectos da cadeia de suprimentos podem ser integrados através de um planejamento avançado da cadeia com uma estrutura hierárquica cuja ideia principal é decompor o plano total de tarefas em módulos de tarefas, isto é, planos parciais, onde o nível mais alto é o estratégico, o intermediário é o operacional e o nível mais baixo é o tático de curto prazo (MILLER, 2002).

Valendo-se da estrutura hierárquica e classificando as tarefas de planejamento em duas dimensões, uma em “horizonte de planejamento” (curto, médio e longo prazo) e outra em “processos da cadeia de suprimento”, temos a SCP-Matrix, com uma visão integrada do planejamento da cadeia de suprimentos a relação entre as atividades de curto , médio e longo prazo (Figura 3) (IVANOV; TSIPOULANIDIS; SCHÖNBERGER, 2019).

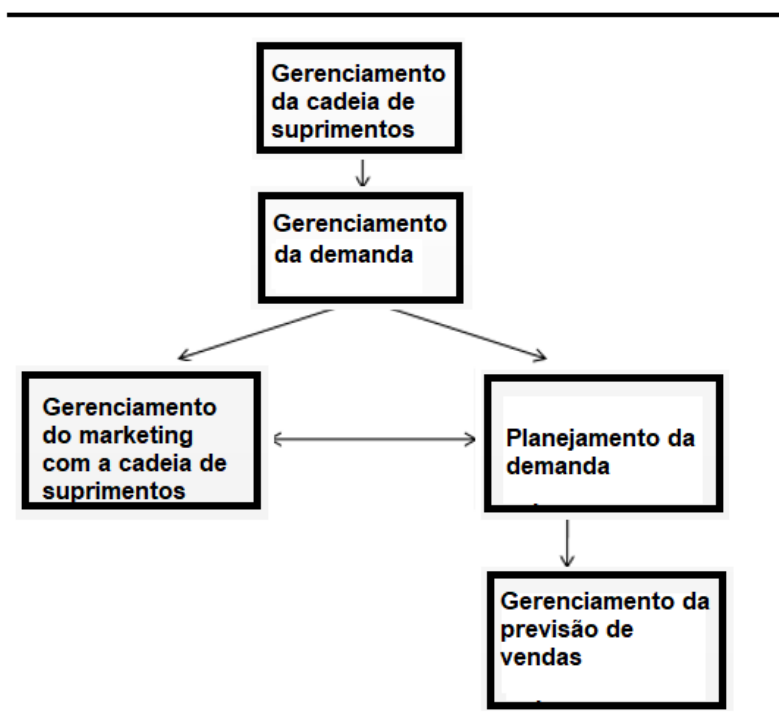


Figura 2- O papel do gerenciamento da demanda dentro do gerenciamento da cadeia de suprimentos

Fonte: (MENTZER; MOON, 2005).

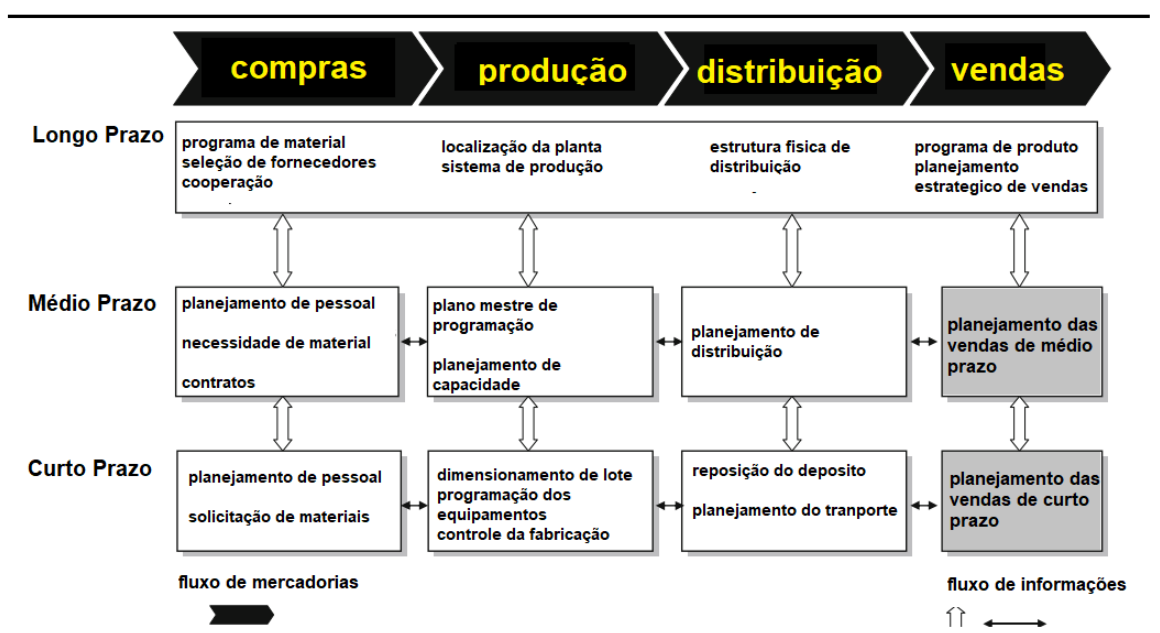


Figura 3- Matriz de planejamento de suprimentos (SCM – Matrix)

Fonte: (IVANOV; TSIPOULANIDIS; SCHÖNBERGER, 2019).

Tendo como visão geral do gerenciamento da cadeia de suprimentos a SCM-Matrix, nosso estudo se concentrará na previsão do volume de vendas do médio e curto prazo.

## **2.2 Previsão de vendas**

O gerenciamento da previsão de vendas é uma função da organização para entender o que o consumidor está demandando, assim será possível atender vendas ou se aproximar do nível dessas necessidades. A previsão de vendas , pode ser definida , como uma projeção no futuro de uma demanda esperada, dado um conjunto de condições ambientais (MENTZER; MOON, 2005). Isto deve ser distinguido do planejamento operacional, que é um conjunto de ações para alcançar as previsões de vendas ou excede-las.

A mudança das condições de competitividade global nos últimos anos tem criado um ambiente muito volátil, dificultando as projeções de demanda. A consolidação de indústrias, a globalização e a manufatura enxuta, coloca mais estresse na cadeia de suprimentos tornando ainda mais complicado gerar respostas mais eficientes em relação às mudanças de demanda.

Muitas empresas ainda confundem a função de previsão com planejamento de estabelecimento de metas. A previsão busca a acurácia, já o objetivo das metas é superar as quotas. Portanto o planejamento operacional deve ter o resultado da previsão e as metas estabelecidas pela gestão das vendas (MENTZER, MOON, 2005).

Previsão é uma tarefa estatística nos negócios que nos ajuda a tomar decisões a respeito de plano de produção, transporte, pessoal e tem o objetivo de prover informações para nos guiar no planejamento estratégico (HYNDMAN; ATHANASOPOULOS, 2018).

Existem três diferentes aspectos, e fim de evitar confusão de entendimento entre previsão, planejamento e metas; primeiramente a Previsão, que é a capacidade

de antever o futuro tão preciso quanto possível, dado as informações disponíveis, dados históricos e qualquer evento que possa impactar a visão de futuro; as Metas, que é o que gostaríamos que acontecesse, e deve ser conectada com a previsão, mas nem sempre isso ocorre, e por último o Planejamento, que envolve ações que fazem com que as previsões atinjam as metas.

As organizações modernas requerem previsões de curto, médio e longo prazo dependendo da aplicação específica (HYNDMAN; ATHANASOPOULOS, 2008);

- . Curto prazo, são necessárias para a programação de pessoal, produção e transporte

- . Médio prazo, determina as necessidades de recursos, compras de matéria prima, contratação de pessoal, compra de máquinas

- . Longo prazo, usado para planejamento estratégico, considerando as oportunidades de marketing, fatores ambientais e recursos internos.

Em diversas empresas a previsão de vendas é parte integral do processo que combina demanda com suprimentos conhecida como "Sales and Operations Planning" (S&OP) (Figura 4). A função demanda é de responsabilidade de vendas e marketing, e suprimentos é de responsabilidade de várias funções, incluindo produção, compras, distribuição, recursos humanos e finanças (MENTZER; MOON, 2005).

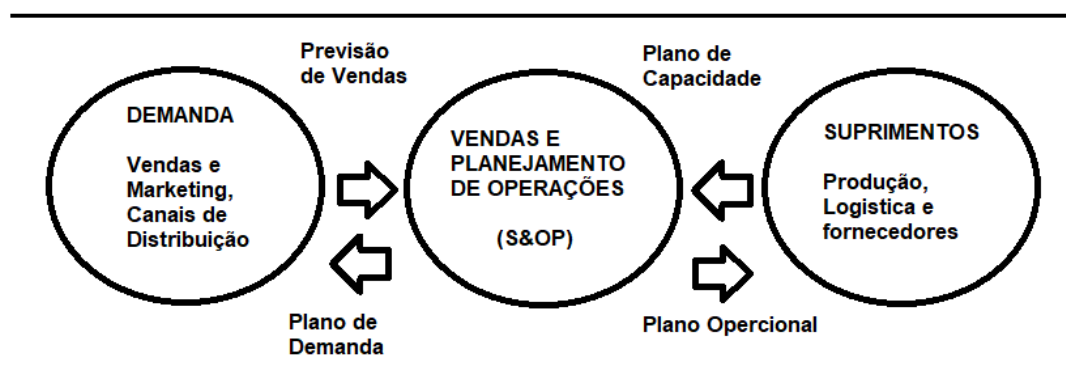


Figura 4- Integração Vendas e Planejamento de Operações (S&OP)

Fonte: (MENTZER; MOON, 2005).



Estudos conduzidos na última década mostraram que um aumento de dois a dez por cento de melhoria na acurácia na previsão de demanda induz a um incremento de cinco a sete por cento na receita e crescimento do lucro. Implementar uma estratégia de previsão de demanda, permite suportar um período de incremento de vendas com um menor nível de estoques, melhorar a acurácia da previsão para produtos com baixo volume de vendas enquanto mantem o atendimento para produtos de alto volume, alcançar melhor retorno dos investimentos, do lucro, reduzir os custos de estoques e capital de giro (CHASE, 2016).

Em previsão procuramos estimar como a sequência de observações dos dados históricos continuará no futuro, essa sequência é conhecida como série temporal. Um passo importante para selecionar o método apropriado é considerar o tipo de padrão dos dados, e assim selecionar o mais apropriado.

Há quatro tipos de padrões de séries que podem ser distinguidas como: horizontal, sazonal, cíclica e tendência. Esses padrões podem, muitas vezes, vir combinados em uma mesma série (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008):

- . Padrão horizontal: existe quando os dados flutuam em torno de uma média, é chamado também de estacionário. Quando por exemplo as vendas não sobem e não descem ao longo do tempo;

- . Padrão sazonal: ocorre quando a demanda é afetada por fatores sazonais como época do ano, dia da semana ou por questões ligadas as estações climáticas do ano;

- . Padrão cíclico: existe quando os dados aumentam e diminuem em um período não fixo, influenciados por flutuações econômicas. A diferença entre variações sazonais com cíclicas é que a primeira é constante em períodos e ocorre em períodos regulares enquanto o cíclico varia em maior período;

- . Tendência: acontece quando há um aumento ou diminuição no longo prazo;

. Padrão aleatório: consiste de irregularidade na série de dados, qualquer variação na série temporal que não pode ser atribuída a um padrão de tendência, sazonal ou cíclica, se enquadra nesta categoria.




Figura 5- Exemplos de padrões de séries temporais

Fonte: (HYNDMAN; ATHANASOPOULOS, 2018).

A Figura 5 exemplifica diferentes combinações desses padrões:

- . A venda mensal de casa mostra uma sazonalidade e também um comportamento de ciclo com um período de aproximadamente 5 anos;
- . O título do tesouro americano não há sazonalidade, mas uma tendência de queda;
- . A produção de eletricidade na Austrália mostra uma tendência forte de crescimento com sazonalidade;
- . As mudanças do preço de fechamento das ações do Google, não possuem sazonalidade, tendência ou ciclo, apenas uma flutuação aleatória em torno de uma média (HYNDMAN; ATHANASOPOULOS, 2018).

Técnicas de previsão de vendas se enquadram em duas categorias, as análises subjetivas ou estatísticas. E em relação aos dados, se são endógenos, isto é, se existem históricos de vendas ou outros que expliquem a variação em vendas

(promoções, ações da concorrência em vendas ou medidas econômicas) (MENTZER; MOON, 2005).

A primeira categoria envolve modelos qualitativos já a segunda é de natureza quantitativa e usa modelos matemáticos para desenvolver a previsão (Figura 6).

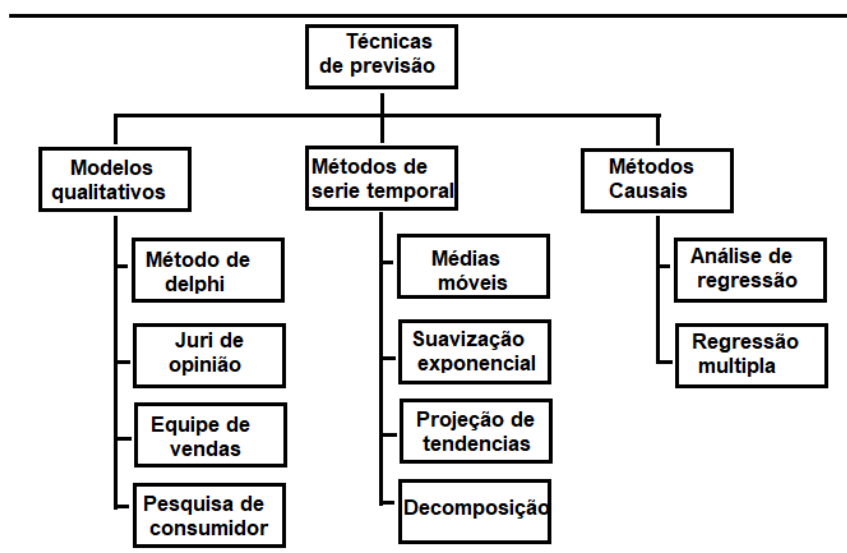


Figura 6 - Modelos de previsão

Fonte: (RENDER, 2018).

Modelos qualitativos; são baseados em julgamentos ou fatores subjetivos, como por exemplo, o lançamento de um produto novo, diferente dos demais e sem histórico, neste caso a empresa necessita basear-se na opinião de especialistas. As seguintes técnicas são usadas para este tipo de modelo (HYNDMAN; ATHANASOPOULOS, 2018):

. Método Delphi; é um processo iterativo com grupos de especialistas, localizados em diferentes lugares, empresas ou outros tipos de organizações. Um questionário é enviado para todos e a resposta recebida é então sumariada e novamente enviada para os participantes, que novamente avaliam e respondem. Esse ciclo é composto das seguintes etapas:

. Consenso de opinião de executivos; esse método coleta a opinião de vários executivos de alto nível, muitas vezes combinado com análises estatísticas e resulta em uma estimativa de demanda;

. Equipe de vendas; pessoas diretamente envolvida com as vendas, fornecem suas estimativas e após consolidam com todas as regiões, é avaliada pela direção de vendas então o número final da previsão é definido;

. Pesquisa de mercado de consumidor; feita diretamente com o consumidor atual ou potenciais, a respeito de futuras compras. Este tipo de pesquisa também ajuda identificar melhorias no projeto do produto ou para lançamentos de novos produtos.

Dentre os vários modelos matemáticos possíveis destacam-se os modelos de séries temporais que consistem em empregar valores de instantes anteriores para tentar prever valores posteriores. Para tanto, usualmente emprega um modelo matemático que procura descobrir os padrões dos dados históricos e extrapola-los para o futuro. (MAKRIDAKIS; WHEELWRIGHT.; HYNDMAN, 2008).

Os modelos causais ou explanatórios são identificados pelo fato da variável que está sendo prevista ser influenciada ou correlacionada com outras variáveis incluídas no modelo. Por exemplo, a venda de suco pode estar sendo influenciada pela temperatura da estação, ou seja, a variável dependente “y” é uma função de variável independente “x”, no exemplo, o suco, variável “y”, é dependente da variável “x” temperatura. Os modelos de regressão simples e múltiplas são classificados como modelos causais. (RENDER, 2018).

Segundo Mentzer e Moon (2005) as técnicas de previsão podem ser divididas entre aquelas que usam análises estatísticas ou subjetivas. As que usam dados chamados exógenos, série histórica e nenhum outro que expliquem o comportamento das vendas, são as séries temporais. O uso de dados endógenos, aqueles externos, que explicam o comportamento da variável que está sendo prevista de vendas, são os métodos de regressão. Há, segundo os autores, os seguintes tipos de técnicas de previsão:

. **Modelo aberto de séries temporais (Open-model time series - OTMS):** constroem o modelo de previsão após observar a série histórica e identificar a existência de padrões. Este tipo de modelo é baseado na relação dos padrões de nível,

tendência, sazonalidade e aleatoriedade. O padrão de nível quando não há uma variação do volume de vendas, a tendência é quando ocorre um crescimento ou decréscimo de vendas, a sazonalidade são as variações que ocorrem em ciclos constantes, e a aleatoriedade são as variações de volumes que não se preveem. O modelo Box-Jenkins, é um exemplo de OTMS.

. **Modelo fixo de série temporal (Fixed-Model time series – FMTS):** Em situações onde temos um horizonte de tempo curto, mudanças rápidas de vendas e necessidade de um grande número de previsões recomenda-se o uso de técnicas simples e adaptáveis. Esse tipo de modelo identifica os mesmos padrões de nível, tendência, sazonalidade e aleatoriedade, considera-se que existem na série histórica e os projeta para o futuro. A suavização exponencial é uma técnica deste modelo.

. **Análises de regressão e correlação:** É uma abordagem estatística de previsão que busca estabelecer uma relação entre vendas e variáveis exógenas, são afetadas pela publicidade, qualidade, preço, serviços de atendimento e econômicas. Quando há uma forte relação entre as variáveis exógenas (independente) e a prevista (dependente), essas variáveis independentes podem ser usadas para projetar as vendas futuras. A regressão é uma das técnicas mais precisas, porém há necessidade de uma quantidade grande de dados.

. **Técnicas qualitativas (Subjetivas):** são usadas quando não há um histórico de demanda disponível, como no caso de lançamentos de novos produtos, mudanças no mercado, nos padrões de distribuição, situações em que o comportamento do passado não é relevante. Essa técnica usa a opinião de pessoas experientes em diferentes áreas da organização necessitando de poucos dados formais para gerar as previsões. O estabelecimento de metas de vendas, em muitas empresas é feito usando essa abordagem.

Segundo Stadtler, Kilger e Meyr, (2015) o planejamento da demanda na qual as atividades de previsão de demanda estão inseridas, consiste de múltiplas fases:

. Fase 1, o processo começa com a preparação pelo departamento central de planejamento dos dados;

. Fase 2, a previsão estatística é feita baseada em dados atualizados;

. Fase 3, a avaliação e julgamento das previsões é feita por múltiplos departamentos.

A integração das áreas para fazer a avaliação e julgamento das previsões é descrita através de cinco procedimentos (GOODWIN; WRIGHT, 2014):

. **Revisão da previsão** – nesta primeira etapa a experiência dos planejadores da demanda, com suas estimativas pessoais avaliam o resultado do método estatístico, ao final temos uma previsão com melhor acurácia, pelo fato de ter incorporado a experiência da equipe.

. **Previsão composta** – a combinação dos pesos dados pela equipe as estimativas iniciais, combinadas com resultado do modelo estatístico, deve produzir uma previsão melhor.

. **Revisão de previsão** – modifica a previsão estatística em função de elementos que possam ter alterado a situação inicial, como por exemplo, promoções comerciais, no serviço de distribuição ou no cenário econômico.

. **Regras de previsão** – escolha do modelo que mais se adequa a realidade baseada no conhecimento da equipe de planejadores.

. **Previsões econométrica** – os modelos de regressão são referidos como modelos econométricos quando há variáveis causais, em especial para previsões de longo prazo.

O resultado da previsão a partir de um processo estruturado de avaliação e julgamento é discutido em reuniões onde diferentes opiniões sobre o que influencia a previsão são consideradas objetivando um resultado final de consenso (GOODWIN; WRIGHT, 2014b).

Segundo Hyndman e Athanasopoulos (2018) a previsão de demanda, envolve as seguintes etapas:

. **Definição do problema:** Esta etapa é normalmente a parte mais difícil em previsão. Definir com cuidado o problema requer o entendimento de como a previsão será usada, quem está solicitando e como ela se adequa as necessidades da organização. Isso requer conversas com várias pessoas e áreas que estão envolvidas na coleta, manutenção do banco de dados e os usuários do resultado final;

. **Coleta de informações:** Nesta etapa são necessários dois tipos de informações: (a) dados estatísticos (b) a experiência acumulada de quem coleta os dados e usa as previsões. Normalmente é difícil obter dados históricos suficientes que se adequem a um bom modelo estatístico. Algumas vezes, dados antigos já não refletem mais a realidade em função das condições do ambiente econômico terem mudado;

. **Análise preliminar dos dados:** Avaliação das características dos dados, podendo ser usado gráfico para identificar, padrões de tendência, sazonalidade, ciclos ou aleatoriedade;

. **Escolha do modelo:** A escolha do modelo depende da disponibilidade de dados históricos, a relação da variável a ser prevista com as possíveis variáveis explanatórias. É comum nesta etapa comparar mais de um modelo para uso. O modelo é uma construção artificial baseado em algumas premissas e em algumas situações é necessário de uso de parâmetros estimados baseados nos dados históricos.

## 2.3 Séries Temporais – modelos de previsão

De maneira geral, as séries temporais podem ser representadas pelas seguintes equações:

$$Y_t = f(T_t, S_t, E_t), \quad (1)$$

onde:

$Y_t$  = Valor de demanda da série temporal no período t

$T_t$  = Componente de tendência / ciclo no período t

$S_t$  = Componente sazonal no período t

Há duas formas estatísticas de série temporal que podem ser representadas usando abordagem de decomposição com as seguintes equações:

. Forma aditiva: 
$$Y_t = T_t + S_t + E_t \text{ (forma aditiva)} \quad (2)$$

. Forma multiplicativa: 
$$Y_t = T_t \times S_t \times E_t \text{ (forma X)} \quad (3)$$

A forma aditiva é usada quando o comportamento da magnitude da sazonalidade não varia com o nível da série, porém se a flutuação da sazonalidade aumenta ou diminui conforme a variação da demanda, então a forma multiplicativa é mais recomendada.

### 2.3.1 Suavização Exponencial – Holt – Winters

A suavização exponencial é o método mais simples, aplica peso nos dados históricos permitindo dar uma relevância maior para dados mais recentes em detrimento a dados mais antigos ou vice-versa (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008). De forma geral podemos representar com a seguinte equação:

$$F_{t+1} = \alpha_t Y_t + (1 - \alpha_t) F_t \quad (4)$$

Além do método simples há ainda a suavização exponencial pelo método linear de Holt, e a suavização exponencial Holt-Winters:

. **Suavização exponencial método linear de Holt**, incorpora a tendência a suavização exponencial simples, usando duas constantes de suavização  $\alpha$  e  $\beta$  (possuem valores entre 0 e 1) utilizando as equações (5), (6) e (7),

$$\text{Nível} \quad - \quad L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (5)$$

$$\text{Tendência} \quad - \quad b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

$$\text{Previsão} \quad - \quad F_{t+1} = L_t + b_t \quad (7)$$



. **Suavização exponencial método linear de Holt-Winters**, incorpora ao modelo Holt, a constante de sazonalidade de duas maneiras: a multiplicativa através das equações (8), (9), (10) e (11) e a aditiva pelas equações (12), (13), (14) e (15):

**Método multiplicativo**

$$\text{Nível} \quad - \quad L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (8)$$

$$\text{Tendência} \quad - \quad b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (9)$$

$$\text{Sazonalidade} \quad - \quad S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (10)$$

$$\text{Previsão} \quad - \quad F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (11)$$

**Método aditivo**

$$\text{Nível} \quad - \quad L_t = \alpha (Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (12)$$

$$\text{Tendência} \quad b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (13)$$

$$\text{Sazonalidade} \quad - \quad S_t = \gamma (Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (14)$$

$$\text{Previsão} \quad - \quad F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (15)$$

### 2.3.2 Regressão múltipla

A regressão múltipla é uma abordagem estatística de correlação para previsão que procura estabelecer uma relação entre uma variável a ser prevista, vendas por exemplo, e duas ou mais variáveis exógenas, explanatórias que afetam a variável a ser prevista, como por exemplo investimento em propaganda, preço ou econômicas (MENTZER; MOON, 2005).

A forma geral da regressão múltipla, pode ser representado pela seguinte equação:

$$Y_t = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_t + e_t, \quad (16)$$

onde:

$Y_t$  = demanda no período t

$x_t$  = variável explanatória no período t

$\beta_t$  = coeficiente da regressão no período t

$e_t$  = estimativa do erro no período t

Os coeficientes são estimados aplicando o método dos mínimos quadrados, minimizando a soma dos quadrados dos erros, uma vez achados os coeficientes uma nova equação da correlação pode ser escrita.

$$\hat{Y}_t = b_0 + b_1 \hat{x}_1 + b_2 \hat{x}_2 + \dots + b_t \hat{x}_t \quad (17)$$

onde:

$\hat{Y}_t$  = previsão no período t

$\hat{x}_t$  = valor de variável independente no período t

$b_0$  = intercepto (valor de Y quando  $x_t = 0$ )

$b_t$  = valor do coeficiente da variável independente t

Para fazer uma nova previsão para valores futuros de “ $\hat{Y}_t$ ” utilizamos a equação (17), com os valores previstos das variáveis independentes “ $\hat{x}_t$ ” e de posse dos coeficientes “ $b_t$ ”, anteriormente calculados, podemos obter o valor da previsão  $\hat{Y}_t$  no período t.

Segundo Cecatto e Belfiore (2015) para as empresas de alimentos pesquisadas, que usam regressão linear em suas projeções de demanda, a variável “tipo de produto” é o fator principal para a escolha do modelo.

## 2.4. Redes Neurais Artificiais

A primeira publicação sobre computação neural data de 1943, quando McCulloch e Walter Pitts compôs o primeiro modelo inspirado em neurônios artificiais, descrevia o neurônio como uma unidade computacional, com várias entradas e uma saída. Seis anos mais tarde Donald Hebb em seu livro “A organização do comportamento”, proveu o elo que faltava postulando que as vias neurais são fortalecidas cada vez que são usadas, então a primeira regra matemática implementando o aprendizado numa Rede neural é descrita. Em paralelo a ciência da computação avançava (MARINI, 2020).

Em 1958, Frank Rosenblatt, com base nos estudos de McCulloch e Pitts, e estudos em visão de moscas, desenvolveu a primeira Rede neural artificial, baseado numa unidade chamada de “perceptron”. Uma camada se mostrou útil para classificar valores contínuos de entrada em uma de duas classes. O perceptron calcula uma soma ponderada das entradas, subtrai um limite e transmite um dos dois valores possíveis como resultado. Variações da Rede neural artificial baseada no conceito de perceptron foram desenvolvidas por Rosenblatt e por Bernard Widrow e Marcian Hoff, sendo que esses dois últimos desenvolveram uma rede chamada ADALINE (Adaptive Linear Element) e mais tarde desenvolveu a MADALINE, que seria Multiple ADALINE, forma os primeiros modelos a serem aplicados em problemas do mundo real.

Em 1969, Marvin Minsky e Seymour Papert, publicaram um estudo mostrando que da maneira que o perceptron estava sendo usado apresentava sérias limitações, que não podiam ser superadas por adicionar mais neurônios a uma rede e demonstraram também que o perceptron era incapaz de resolver o problema de classificação do tipo “XOR”. A desilusão tomou conta dos pesquisadores na década de 70, e muitos deixaram a pesquisa em Redes neurais artificiais.

A retomada da motivação pelo assunto das redes neurais se deve a publicação em 1982, quando John Hopfield, apresentou um artigo para a Academia Nacional de Ciências dos Estados Unidos, no qual postulava que a inteligência

artificial não deveria apenas imitar o cérebro humana, mas sim usar esse conceito para construir máquinas que resolvam problemas dinâmicos. Ele introduziu dois conceitos chaves que permitiram superar as limitações apontadas por Minsky e Papert, que é a não linearidade entre o input total recebido pelo neurônio e a saída que ele produz e da possibilidade de retroalimentação do output com o input. A clareza e acurácia da análise matemática apresentada convenceram os cientistas e pesquisadores da Academia Nacional de Ciências dos Estados Unidos renovarem o interesse pelas redes neurais artificiais. Nos últimos anos as pesquisas avançaram permitindo chegar ao momento atual com as regras de aprendizado sendo ampliadas para redes com várias camadas (MARINI, 2020).

#### 2.4.1 Neurônio Artificial

A estrutura de uma Rede neural artificial foi desenvolvida a partir de modelos do sistema nervoso do cérebro humano. Esses modelos foram inspirados no funcionamento das células dos neurônios geram e propagam impulsos eletricos pelos pesquisadores Hodghin e Huxley em 1952.

Os neurônios usados nas redes neurais são não-lineares, promovem saídas continuas, excutam funções simples, como coletar sinais dos inputs, consolidam-os de acordo com funções operacionais e produzem respostas considerando as funções de ativação.

O modelo simples de neurônios artificiais que incorporam características de uma rede de neurônios cerebrais com paralelismo e alta conectividade foi proposto preliminarmente por McCulloch e Pitts em 1943, é ainda o modelo mais usado em diferentes arquiteturas de redes.

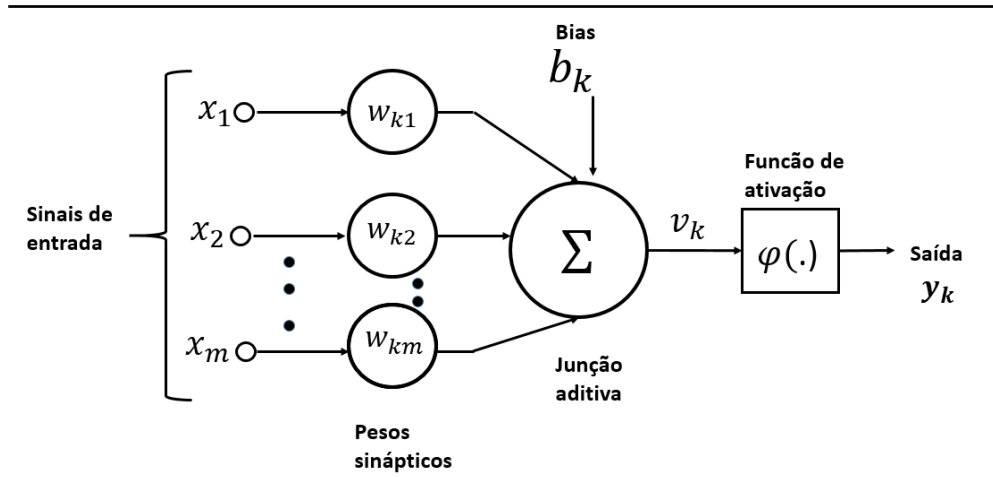


Figura 7 - Modelo não-linear de um neurônio

Fonte: Adaptado de HAYKIN (2007).

Esse neurônio artificial pode ser descrito com as seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (18)$$

$$y_k = \varphi(u_k + b_k) \quad (19)$$

$$v_k = u_k + b_k \quad (20)$$

$$y_k = \varphi(v_k) \quad (21)$$

Considerando a Figura 7, observamos neste neurônio artificial sete elementos básicos que são (HAYKIN, 2007):

- Sinais de input** ( $x_1, x_2, \dots, x_m$ ) - são sinais de entrada da sinapse, que vem do ambiente externo e representa valores de uma variável particular, conectado a um neurônio  $k$ , normalmente o sinal de input é normalizado para melhorar a eficiência do algoritmo de aprendizagem.
- Pesos das sinapses** ( $w_{k1}, w_{k2}, \dots, w_{km}$ ) - são valores de pesos usados para calibrar cada uma das variáveis de entrada permitindo quantificar a relevância para esse neurônio.

- c. **Agregador linear (somador) (  $\Sigma$  )** – soma todos os sinais de entrada ponderado pelos respectivos pesos das sinapses, constituindo um combinador linear.
- d. **Limiar de ativação (  $b_k$  )** – variável usada para especificar os limites da saída do somador deve ter para gerar a saída do neurônio.
- e. **Potencial de ativação (  $v_k$  )** – é o resultado da diferença entre o somador e o limiar de ativação.
- f. **Função de ativação (  $\varphi ( \cdot )$  )** – limita a saída do neurônio para um valor razoável.
- g. **Sinal de saída do neurônio (  $y_k$  )** – resultado final de saída do neurônio, dado um conjunto de sinais de entrada, pode ser ainda usado como entrada para um próximo neurônio na sequência.

A função de ativação pode ser caracterizada em dois grupos, funções parcialmente diferenciáveis e funções completamente diferenciáveis, resumidamente suas equações podem ser apresentadas da seguinte forma:

- a. Funções parcialmente diferenciáveis;

$$\text{a.1. Função limiar - } \varphi ( v ) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (22)$$

$$\text{a.2. Função limiar simétrico - } \varphi ( v ) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v = 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (23)$$

$$\text{a.3. Função rampa simétrica - } \varphi ( v ) = \begin{cases} a, & \text{se } v > a \\ v, & \text{se } -a \leq v \leq a \\ -a, & \text{se } v < -a \end{cases} \quad (24)$$

b. Funções completamente diferenciável;

$$\text{b.1. Função logística - } \varphi(v) = \frac{1}{1 + e^{-\beta \cdot v}} \quad (25)$$

onde:

$\beta = \text{inclinação da função logística}$

$$\text{b.2. Função tangente hiperbolica - } \varphi(v) = \frac{1 - e^{-\beta \cdot v}}{1 + e^{-\beta \cdot v}} \quad (26)$$

onde:

$c = \text{parametro que define o centro da função Gaussiana}$

$\sigma = \text{desvio padrão da dispersão em relação ao centro}$

$$\text{b.3. Função Gaussiana - } \varphi(v) = e^{-\frac{(v-c)^2}{2\sigma^2}} \quad (27)$$

$$\text{b.4. Função Linear - } \varphi(v) = v \quad (28)$$

A arquitetura da Rede neural define como os neurônios estão estruturados um em relação ao outro. Treinar uma arquitetura de rede envolve aplicar passos ordenados para ajustar os pesos e os limiares dos neurônios, esse processo, também conhecido como algoritmo de aprendizagem, objetiva ajustar as saídas para os valores desejados.

Uma Rede neural pode ser dividida em três partes, camadas de entrada, camadas intermediárias, e camada de saída. As principais arquiteturas de redes podem ser divididas em (NUNES; DA SILVA, 2018):

a. Rede neural de arquitetura com camada única alimentada adiante;

Nesta configuração há somente uma camada de entrada, uma camada de neurônio que é a camada de saída, com “n” entradas e “m” saídas. A informação flui em uma única direção da camada de entrada para a camada de saída, conforme Figura 8. Esse tipo é empregado em classificação e problemas de filtro linear.




Figura 8 - Exemplo de camada única alimentada para frente

Fonte: (NUNES; DA SILVA, 2018)

- b. Rede neural de arquitetura de múltiplas camadas alimentadas adiantes;

Estas arquiteturas de múltiplas camadas são compostas por um ou mais camadas ocultas. São empregadas em problemas de aproximação, classificação de padrões, identificação, controle de processo e otimização. A Figura 9 mostra uma camada de entrada com “n” sinais de entrada, com duas camadas escondidas com “n1” e “n2” números de neurônios e a camada de saída, composta de “m” neurônios e representa a saída dos valores do problema analisado.

Dentre as redes que usam esta arquitetura destaca-se as “Redes Alimentadas Diretamente com Múltiplas Camadas, também conhecidas no termo em inglês como “Multilayer Perceptron (MLP), e a “Redes Função de Base Radial”, conhecida no termo em inglês como “Radial Basis Function (RBF)”.



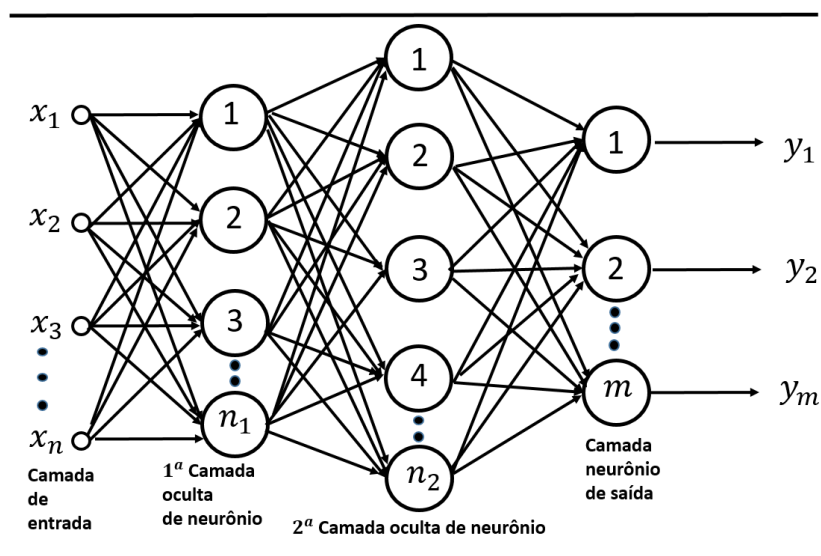


Figura 9 - Exemplo de camadas múltiplas alimentadas para frente

Fonte: (NUNES; DA SILVA, 2018)

- c. Rede neural de arquitetura recorrente, feedback ou retroalimentação;

Neste tipo de redes, os neurônios de saída são usados como feedback de entradas para outros neurônios. Este feedback possibilita o uso desta rede para processamentos dinâmicos de informações, como sistemas de identificação, otimização, controle de processos e algumas outras aplicações.

Dentre as principais redes de feedback estão as de **Hopfield** e a de Perceptron com feedback entre neurônios de diferentes camadas e cujo algoritmo de otimização usado no seu processo de treinamento é baseado na função de minimização de energia. A Figura 10 mostra um exemplo da arquitetura desta rede.




Figura 10 - Exemplo de rede recorrente

Fonte: (NUNES; DA SILVA, 2018)

d. Rede neural em malha;

A característica principal de uma rede em malha é considerar o arranjo dos neurônios para extrair padrões, a localização dos neurônios está diretamente relacionada com o ajuste dos pesos das sinapses e dos seus limites. Este tipo de rede tem uma variada aplicação tal como resolver problemas envolvendo cluster de dados, reconhecimento de padrões, otimização de sistema dentre outras aplicações.

A rede de **Kohonen** é o principal representante da arquitetura de malha e seu treinamento é feito através de um processo competitivo. A Figura 11 ilustra o exemplo da rede tipo Kohonen, onde os neurônios são arranjados em dois espaços dimensionais, observa-se um neurônio e os vários sinais são lidos por todos os neurônios.




Figura 11 - Exemplo de rede em malha

Fonte: (NUNES; DA SILVA, 2018)

O presente estudo utilizou a Rede neural de arquitetura, tipo “MLP”, e cuja arquitetura é tal que é necessário fornecer dados para os quais a saída desejada é conhecida, isto é, usa-se o aprendizado supervisionado. É considerada uma das arquitetura de rede mais versáteis por sua aplicabilidade, tais como (NUNES; DA SILVA, 2018):

- a. Função universal de aproximação (ajuste de curva);
- b. Reconhecimento de padrão;
- c. Identificação de processo e controle;
- d. Previsão de séries temporais;
- e. Otimização de sistema.

A Figura 12 apresenta de forma simplificada a arquitetura deste modelo MLP.

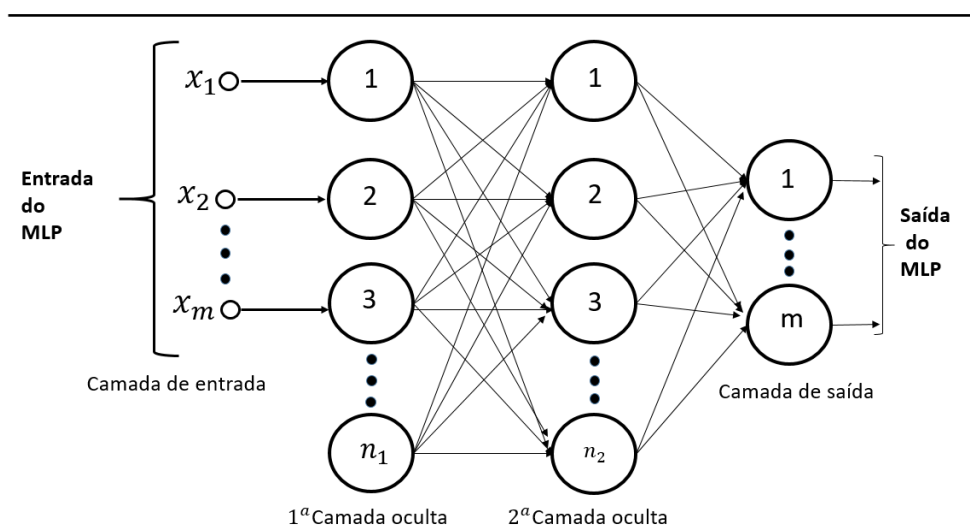


Figura 12- Modelo ilustrativo da estrutura de Rede neural MLP

Fonte: Adaptado de Nunes; Da Silva, (2018).

#### 2.4.2 Medidas de acurácia de previsão

Medir o desempenho da previsão é medir o quão bem conseguimos prever o resultado do modelo e comparar diferentes modelos estatísticos para identificar o que melhor se ajusta nos dados históricos (CHASE, 2013).

As medidas de acurácia das previsões de demanda promovem a melhoria de informação para os planejadores de estoque, para a distribuição os produtos, melhora o nível de serviço de atendimento dos clientes, reduz o nível de capital de giro necessário devido uma redução dos estoques, e melhora a lucratividade final (MENTZER; BIENSTOCK; KAHN, 1999).

Tendo as observações dos dados e as previsões no mesmo período, podemos definir o erro da previsão e as medidas de acurácia através das equações (29 a 36) segundo Makridakis, Wheelwright e Hyndman (2008):

$$\text{Erro da previsão} - e_t = Y_t - F_t \quad (29)$$

onde:

$Y_t$  – dado observado

$F_t$  – previsão para o mesmo período

$$\text{Erro Médio} = \frac{1}{n} \sum_{t=1}^n e_t \quad (30)$$

$$\text{Erro Médio Absoluto} = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (31)$$

$$\text{Erro Médio Quadrático} = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (32)$$

$$\text{Raiz Quadrada do Erro Médio Quadrático} = \left( \frac{1}{n} \sum_{t=1}^n e_t^2 \right)^{\frac{1}{2}} \quad (33)$$

As seguintes medidas relativas são também muito utilizadas,

$$\text{Erro percentual} - PE = \left( \frac{Y_t - F_t}{Y_t} \right) \times 100 \quad (34)$$

$$\text{Erro médio percentual} = \frac{1}{n} \sum_{t=1}^n PE_t \quad (35)$$

$$\text{Erro médio percentual absoluto} = \frac{1}{n} \sum_{t=1}^n |PE_t| \quad (36)$$

O **erro médio** (30) tende a ser pequeno uma vez que os erros positivos e negativos se somam, essa medida somente irá nos indicar se há uma previsão muito abaixo ou muito acima, porém não indica a dimensão do erro. A medida **erro médio absoluto** (31), torna os valores todos positivos. Uma ideia parecida está por trás da definição do **erro médio quadrático** (32), neste caso o erro se torna positivo ao levá-lo ao quadrado, em seguida faz-se a média. A extensão do erro médio quadrático, tomando a raiz quadrada deste temos a **raiz quadrada do erro médio quadrático** (33), também conhecida na literatura por Root Mean Square Error (RMSE).

Essas medidas não facilitam a comparação entre diferentes séries de dados, para fazer isso é necessário ter o **erro relativo ou percentual** (34). O **erro médio percentual** (35) tende a ter um valor pequeno negativo ou positivo, para resolver, tomamos o valor absoluto do erro percentual e tiramos a média, resultando no **erro médio percentual absoluto** (36), também conhecido na literatura como MAPE (Mean Absolute Percentage Error) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008).

No presente estudo foi utilizado o MAPE, uma vez que é largamente utilizado para medir a acurácia dos modelos de previsão (MAKRIDAKIS, 1993).

### 2.4.3 Rede neural aplicada na previsão de demanda no setor de varejo de alimentos

A previsão de demanda do setor de alimentos é particularmente importante, pois os produtos possuem prazos de validade, podendo gerar penalidade para o estabelecimento que possuir em seus estoques produtos vencidos. Portanto, saber o quanto comprar e quando é um fator decisivo na competitividade da loja.

A importância da previsão para este setor torna-se, portanto crucial, pois as sobras de produtos nas lojas que não forem vendidos acarretam em custo de devolução ou de descarte para incineração. Já a falta do produto gera perda de receita e consequentemente prejuízo operacional.

A difícil tarefa de se equilibrar entre a sobra ou a falta de produto torna-se um grande desafio nos dias atuais, onde o número elevado de opções de compras e um consumidor cada vez mais informado pelas mídias sociais, exige um sistema de monitoramento e alerta que antecipe um desequilíbrio entre esses dois polos opostos.

A indústria fornecedora de alimentos, abastecendo as grandes cadeias de lojas, é preponderante no sentido de evitar que a sobra ou a falta, seja uma constância, gerando com isso prejuízos para toda a cadeia.

A previsão de demanda de produtos alimentícios, objeto de nosso estudo, exerce, portanto, um papel crucial no sentido de instrumentalizar os tomadores de decisão da cadeia de produção e fornecimento.

Embora as tecnologias de previsão e os modelos terem avançados, a indústria de alimentos no Brasil escolhe seus modelos de previsão, tendo como premissas principais o tipo de produto, a facilidade de uso dos modelos e de pessoal qualificado para uso do modelo escolhido (CECATTO; BELFIORE, 2015).

O processo de previsão neste setor deve considerar algumas decisões importantes, tais como (TSOUMAKAS, 2019):

- a. Quanto a natureza dos dados, ou seja , se é agregado por categoria ou em unidade específica por tipo de produto específico, se é refrigerado ou não;
- b. Quanto a informação de saída do modelo, a que nível de agregação, periodicidade;
- c. Variáveis de entrada, por ser um segmento muito fragmentado, ter os dados reais de forma correta é um grande desafio, uma vez que muitos pontos de venda, não possuem a rotina de acumular o histórico das vendas, principalmente o pequeno e médio varejo. Já a situação dos dados nas grandes redes é diferente, pois na maioria delas, as informações sobre os dados de produtos vendidos ficam disponíveis nos caixas de pagamento.

No presente estudo foi pesquisado nas bases de dados “Science Direct”, “Emerald” e “Willey” a existência de artigos acadêmicos que contemplassem as seguintes palavras correlatas:

- a. “demand forecasting”
- b. “demand forecasting retail”
- c. “demand forecasting retail food”
- d. "demand forecasting retail food neural networking"
- e. “price” + “media” + “income” + “share”

Foram encontrados os seguintes resultados:

. Base Science Direct – item a) 108645 artigos; item b) 13152 ; item c) 4047 ; item d) 311 ; item e) nenhum.

. Base Emerald – item a) 27000 artigos; item b) 8000 ; item c) 3000 ;item d) 91 ; item e) nenhum.

. Base Willey – item a) 80713 artigos; item b) 63421 ; item c) 5490 ; item d) 138 ; item e) nenhum.

Há muitos trabalhos na literatura sobre previsão de demanda, porém existe uma quantidade menor relacionada com varejo de alimentos e nenhum trabalho considerando as variáveis causais “PREÇO”, “MÍDIA”, “RENDA”, “SHARE”, em conjunto como em nosso estudo.

Segundo Arunraj e Ahrens (2015) não existe um modelo universal que possa ser aplicado para vários tipos de problemas, de acordo com os autores, não podemos ter a expectativa de ter um modelo com boa acurácia para prever o preço de venda e ao mesmo tempo ter uma boa previsão para volume de vendas.

Há diversos fatores que podem influenciar a demanda do consumidor, como forma de pagamento, feriados, férias escolares, clima, variações de preço, tipos de promoção, sendo que todos esses fatores podem ser considerados como dados do neurônio de entrada em uma rede neural (ARUNRAJ; AHRENS, 2015).

Esses fatores, quando associados podem causar uma condição de não-linearidade, o que leva muitas vezes o pesquisador a introduzir metodologias para compensar essas não linearidades (DOGANIS et al., 2005).

As Redes neurais usam modelos de estruturas genéricas mais sofisticadas, que podem incorporar as características de dados complexos e produzir previsões com melhor acurácia (DOGANIS et al., 2005).

Em nosso trabalho, foram utilizadas as Redes neurais, que podem incorporar características complexas de não linearidade dos dados, alimentando os neurônios de entrada com nossas causais, que foram: “PREÇO”, “MÍDIA”, “RENDA”, “SHARE” objetivando como variável de saída, o volume de vendas em toneladas, denominado “VOLUME”.



### 3. METODOLOGIA

#### 3.1 Método - Considerações Gerais

O presente estudo foi de caráter aplicado à realidade de uma atividade industrial do setor de alimentos, foi exploratório, pois permitiu uma melhor compreensão e ao mesmo tempo foi explicativo no sentido de ampliar o conhecimento e de fazer uma previsão de demanda usando dados reais do mercado de varejo. O problema investigado abordou a performance da previsão de demanda de venda de um produto alimentício específico, o biscoito moldado sabor chocolate, considerando como variáveis causais independentes: o “preço”, o “investimento em mídia”, a “renda média” e a “participação de mercado do produto” usando o método tradicional de regressão linear múltipla e uma rede neural artificial.

Uma pesquisa bibliográfica exploratória foi realizada no sentido de identificar e entender as principais contribuições, dificuldades e limitações dos estudos existentes de previsão de demanda voltados para a área de alimentos e as técnicas e modelos empregados, em especial o uso de redes neurais para este tema.

A previsão de demanda com acurácia se faz cada vez mais necessário, na busca de melhorar a rentabilidade do negócio, evitando à falta ou excesso de estoques ou ainda produtos próximos à data de validade de vencimento que não foram vendidos.

Em um estudo realizado na Inglaterra sobre desperdícios ao longo de toda a cadeia alimentar com grandes produtores e varejistas, apontou-se que as previsões de demanda ruins contribuem para o desperdício ao longo da cadeia, além de reconhecer que fazer uma previsão é uma tarefa complexa e afetada por muitos fatores, como o clima, sazonalidade, campanhas de marketing dentre outros (MENA; ADENSO-DIAZ; YURT, 2011).

Nosso estudo buscou informações sobre o biscoito moldado de chocolate junto a um grande produtor de alimentos no país, onde é fabricado em uma linha de

produção dedicada especificamente para este tipo de produto, com uma taxa de produção horária de 3600 kg/h. O programa de produção considera um regime de trabalho de trinta dias no mês e vinte quatro horas por dia, com quatro equipes que se revezam em dias alternados. Os períodos de refeições (café da manhã, almoço e jantar) são realizados com o revezamento interno da própria equipe da linha de produção, evitando com isso interrupções no processo produtivo.

As vendas do referido produto são feitas para todas as grandes redes de supermercados, hipermercados, grandes atacadistas e diversos distribuidores independentes que comprem para revenda ao pequeno varejo.

Todas as ações de marketing para promoção do produto são feitas pela própria empresa, utilizando-se de diversos produtores de conteúdo televisivo, digital e impresso.

As pesquisas de mercado, que monitoram os pontos de vendas coletando as informações dos produtos vendidos, são realizadas por empresa externa, com fornecimento de relatórios mensais de vendas por produto e região.

As equipes de vendas, compostas por diretor comercial, gerentes por regiões e promotores, têm como missão principal atingir as metas de vendas, controlando os pedidos dos varejistas, faturamento e entregas diariamente.

As etapas do método seguirão **os passos básicos para tarefas de previsão** recomendadas por Hyndman e Athanasopoulos (2018).

### **3.2 Método – Descrição das etapas**

A gestão da cadeia de suprimentos tem despertado o interesse cada vez maior das empresas para ganhar vantagem competitiva, embora seja uma tarefa complexa e desafiadora, devido as constantes mudanças de tendência de mercado, variedade de produtos, produtos com ciclos de vida mais curtos e aumento das produções terceirizadas. Quando empresas enfrentam pressões devido ao aumento de estoques, baixo nível de serviço de atendimento ao cliente, custos aumentando e

baixo retorno dos investimentos, são sintomas de que a gestão de demanda está fora de controle (LEE, 2002).

A coordenação do fluxo de informação entre os participantes de cadeia de suprimentos é uma atividade muito importante, que tem um impacto direto na programação de produção, no controle de estoque e nos planos de entrega entre os membros da cadeia. Deve existir uma sincronização nas ordens de compra do varejista para o fabricante, se existir uma distorção nas vendas reais do varejo ao cliente final, esse evento tende a se propagar na direção, no montante, no fornecedor e na indústria, esse fenômeno é conhecido como efeito chicote (LEE; PADMANABHAN; WHANG, 2004).

Uma vez definido o problema a ser abordado pela previsão, os seguintes passos devem ser seguidos:

### 3.2.1 Dados

Os dados relativos ao **volume de venda** (Volume) foram obtidos diretamente de relatórios de pesquisa de mercado elaborado pela Nielsen Company, usados pelos departamentos de vendas e de marketing do fabricante.

As informações relativas a **investimento em mídia** foram obtidas pelos dados contábeis de pagamento desses investimentos diretamente da controladoria industrial.

Os **preços de vendas (Preço)** e de **participação de mercado (Share)** embora sejam administrados pelo departamento de vendas, são realizados pelo departamento de marketing, em conjunto com a empresa de pesquisa Nielsen Company que fazem a compilação dessas informações em relatórios mensais, dos quais os dados sobre preços mensais foram adquiridos. O faturamento mensal do produto foi obtido a partir do relatório de vendas mensais elaborado pelo departamento de vendas.

A série de dados relativos à **renda** média de todos os trabalhadores efetivados (**Renda**) é livremente disponibilizada pelo IPEA, Instituto de Pesquisa Econômica Aplicada.

Esses dados terão as seguintes atribuições na série que serão testadas no modelo:

- a. Volume de venda – variável depende - denominada de “VOLUME”;
- b. Preço – variável independente causal, denominada de “PREÇO”;
- c. Investimento em mídia – variável independente causal denominada de “MÍDIA”;
- d. Renda – variável independente causal denominada “RENDA”;
- e. Participação de mercado do produto – variável independente causal denominada de “SHARE”.

Os modelos de Rede Neural e regressão linear deverão ser testados, com a combinação dessas quatro variáveis gerando quinze combinações possíveis para os dois tipos de modelo, produzindo trinta resultados para cada série de dados testados.

A venda do produto apresenta uma tendência de crescimento e alguns períodos de baixa. Uma pequena amostra ilustrativa dos dados originais a serem utilizados, para um melhor entendimento dos passos subsequentes está apresentada na Tabela 1, os dados completos podem ser encontrados no Apêndice A.

Tabela 1- Dados históricos

Série de dados originais de volume de vendas					
MÊS	VOLUME	PREÇO	MÍDIA	RENDA	SHARE
jul/16	920,03	28,73	237397	1.990	0,49
ago/16	1021,56	28,32	338002	2.020	0,49
set/16	998,33	28,87	109051	2.021	0,49
out/16	1012,80	29,07	269770	2.023	0,50

Fonte: Elaborado pelo autor

### 3.2.2 Análise Exploratória

Nesta etapa, o comportamento dos dados foi analisado, usando um gráfico, a fim de identificar eventuais tendências, ciclos e comportamentos

irregulares. Tendo como objetivo de previsão o “volume de vendas”(VOLUME) , essa variável dependente é a que foi analisada graficamente seu comportamento.

As variáveis independentes, “preço”(PREÇO), “investimento em mídia (MÍDIA)”, “renda”(RENDIA) e “participação de mercado (SHARE)”, foram avaliadas por testes de “Heteroscedasticidade” e “Colinearidade”, com o intuito de verificar se há alguma relação causal entre elas que possam comprometer o resultado do modelo.

### 3.2.2.1Análise Exploratória –Variável Dependente

O comportamento dos dados de volume de venda pode ser observado através do gráfico apresentado na Figura 13. Nota-se uma tendência crescente do volume de vendas com quedas no mesmo mês de janeiro ao longo dos anos, pequenos ciclos de alta no segundo semestres de cada ano e algumas irregularidades.




Figura 13 - Análise Exploratória - Variável dependente - Volume de vendas (VOLUME)

Fonte: Elaborado pelo autor.

Tendo em vista o volume de vendas, foi interessante compara-lo com o comportamento do volume faturado para o varejista final, a fim de entendermos o fluxo de volume ao longo dos meses, entre o que sai da fábrica vendido para o varejo e o que o varejista vende para o cliente final.

Nota-se claramente na Figura 14 um descompasso entre a ordem de compra recebida pelo fabricante vinda do cliente (redes de supermercados) e o que é vendida pelo cliente ao consumidor no varejo final, na loja.




Figura 14 - Análise Exploratória - Variável dependente - volume faturado e de vendas do varejo ao cliente final

Fonte: Elaborado pelo autor.

A esse descompasso é atribuído o nome de “efeito chicote” (“bullwhip effect”), descrito como uma variação do volume de pedidos recebidos pelo fornecedor em relação ao volume de pedidos que são recebidos pelo cliente. Esse fenômeno não é novo e é conhecido há algum tempo pelos estudiosos das cadeias de suprimentos. O primeiro a estudar esse fenômeno foi Forrester, 1961, em seu livro

“Industrial Dynamics” onde apontou as consequências para a organização dessa dinâmica industrial (LEE; PADMANABHAN; WHANG, 2004).

Sterman (1989), em seu experimente “denominado jogo da cerveja”, envolvendo quatro jogadores que decidem volume de estoques independentes sem consultar os elos da cadeia de fornecimento e clientes, mostrou que a variação das ordens de compra amplifica na medida em que se movem a montante na cadeia de fornecimento. Ele interpretou esse fenômeno como um comportamento sistemático irracional dos jogadores ou uma interpretação equivocada das respostas dos agentes da cadeia de suprimentos (LEE; PADMANABHAN; WHANG, 2004).

Esse termo, efeito chicote, foi primeiramente usado pela empresa “Procter & Gamble”, quando experimentaram um recebimento de ordens de fabricação que não eram compatíveis com a demanda do produto final junto ao consumidor, resultado da distorção de informações ao longo da cadeia de suprimentos (LEE; PADMANABHAN; WHANG, 2004).

A distorção da informação implica que o fabricante que olha tão somente a ordem e desconsidera a amplificação da demanda por parte dos clientes, incorre em um excesso de estoque de produto acabado.

O efeito chicote provoca distorções em toda cadeia de suprimentos para este produto, acarretando mais estoques, durante todo o período, aumento de custos de materiais estocados, mão de obra já paga e incorporada ao produto em estoque, ou seja, custos ocultos, devido à falta de um sincronismo mais adequado, que minimize esses prejuízos.

A Figura 15 nos mostra o volume de estoques do produto, ao final de cada mês. Essas variações constantes de estoque são claramente resultado do descompasso mostrado na Figura 14.

Portanto, ter uma previsão de volumes de vendas com uma acurácia melhor e de fácil obtenção, certamente contribui em reduzir esse descompasso e os custos envolvidos em estoques adicionais (LEE; PADMANABHAN; WHANG, 2004).




Figura 15- Análise Exploratória - Variável dependente - volume de vendas

Fonte: Elaborado pelo autor.

Após essa análise exploratória gráfica, nota-se que nesses dados estão embutidos comportamentos de **tendência**, **sazonalidade**, **ciclo** e de **irregularidade**. As equações (1), (2) e (3) foram utilizadas para quantificar esses quatro elementos.

### 3.2.2.2 Análise Exploratória –Variáveis Independentes

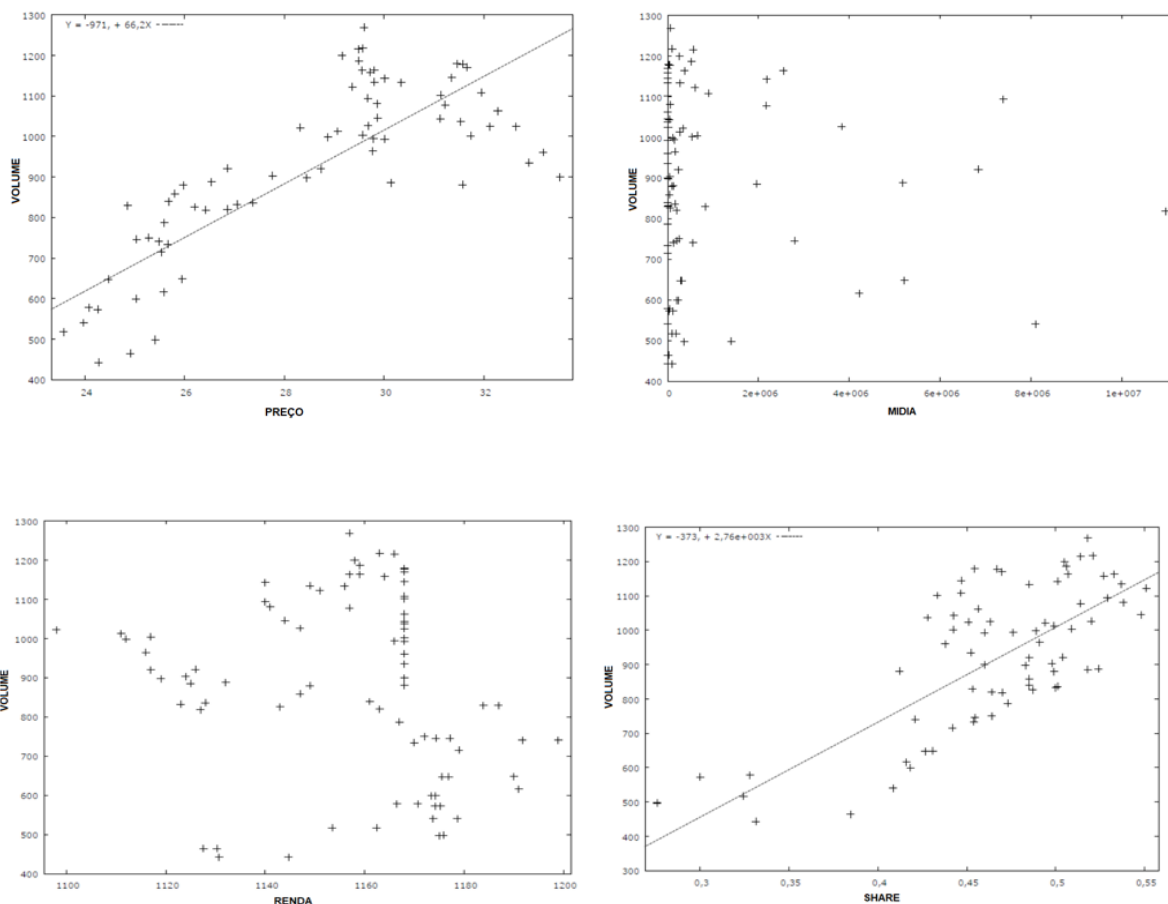
A avaliação dos dados com o uso do software livre “Gretl”, indicou que não há colinearidade nem tão pouco heteoscedasticidade nos dados analisados. Nos Apêndices A e B podem ser observados esses resultados.

A estatística de análise de variância, conhecida também como “ANOVA”, mostrou um valor “ $p < 0,05$ ”, que a regressão, tendo como VOLUME como variável dependente e as variáveis independentes causais: PREÇO, MÍDIA, RENDA e SHARE tem significância (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008), os resultados estão apresentados no Apêndice C e D.

Segundo Makridakis, Wheelwright e Hyndman (2008) é recomendável que sejam feitos gráficos de dispersão, onde os comportamentos dos dados ao longo de tempo possam ser sentidos em termos de tendência, períodos cíclicos e irregulares.

A dispersão dos dados de nosso estudo com as variáveis “PREÇO”, “MÍDIA”, “RENDA” e “SHARE” pode ser observado na Figura 16.





1

Figura 16- Análise Exploratória - Variável independente – dispersão dos dados

Fonte: Elaborado pelo autor.

### 3.2.3 Escolha do Modelo

Como observado na Figura 13, em nossa série de dados houve uma tendência de crescimento ao longo dos anos, apresentando também ciclos e irregularidades. O resultado dos testes estatísticos feito no item anterior indicou que podemos prosseguir com essa mostra, no sentido de buscar um modelo de previsão que melhor se adeque as relações entre o volume de vendas e as variáveis causais de RENDA, MÍDIA, RENDA e SHARE.

Foram escolhidos dois caminhos para nossa previsão, um primeiro, tradicional que é a regressão múltipla e um segundo utilizando uma rede neural artificial.

Em ambos os caminhos, foram considerados em nosso modelo, os efeitos da tendência, ciclos e irregularidades, para tanto foram feitos os ajustes necessários usando o método de decomposição clássica calculando os índices de correção para cada um desses comportamentos.

Foi seguido o conceito da decomposição clássica, baseado na abordagem de Makridakis, Wheelwright e Hyndman (2008), e uma vez obtida a série temporal corrigida, foi usada da seguinte forma:

- a. Utilizar como dados de entrada na rede neural artificial;
- b. Produzir uma regressão múltipla utilizando-se o Excel;
- c. Comparar o resultado de “a”, com o produzido a partir do uso da série sem as correções de tendência, ciclo e irregularidades, no sentido de identificar as diferenças de acurácia da previsão, com e sem o uso da decomposição clássica.

### 3.2.3.1 Decomposição da Clássica

O método clássico de decomposição foi originado em 1920 e é relativamente simples e foi considerado o método básico para muitos outros métodos que se seguiram. Há duas formas de decomposição: a aditiva e a multiplicativa (HYNDMAN; ATHANASOPOULOS, 2018).

Na decomposição clássica, é assumido que os componentes sazonais são constantes de um ano para outro e esse processo de decomposição pode ser realizado utilizando as Equações 1, 2 e 3 anteriormente definidas.

A fim de avaliar qual o modelo de previsão apresentou os melhores resultados de acurácia, considerando as peculiaridades de tendência, ciclos e

irregularidades da série de dados, foi feita a decomposição pelos dois métodos, o aditivo e o multiplicativo e testado em nosso modelo.

A partir da série de dados originais de volume de venda (Tabela 2) é iniciado o processo de decomposição, com o estabelecimento das linhas de tendência.

Tabela 2- Série de dados originais de volume de vendas

Série dados originais de volume de vendas													
Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume
jan/13	464,62	jan/14	540,23	jan/15	615,93	jan/16	832,68	jan/17	885,54	jan/18	1077,92	jan/19	899,56
fev/13	464,62	fev/14	540,23	fev/15	648,20	fev/16	887,45	fev/17	1026,15	fev/18	1142,50	fev/19	1024,49
mar/13	442,68	mar/14	647,25	mar/15	715,11	mar/16	920,78	mar/17	1094,02	mar/18	1268,33	mar/19	1024,33
abr/13	442,68	abr/14	647,25	abr/15	749,93	abr/16	835,95	abr/17	1080,39	abr/18	1163,38	abr/19	1062,27
mai/13	517,29	mai/14	599,14	mai/15	733,96	mai/16	902,88	mai/17	1045,20	mai/18	1217,03	mai/19	960,56
jun/13	517,29	jun/14	599,14	jun/15	787,19	jun/16	897,39	jun/17	1134,21	jun/18	1215,27	jun/19	1108,24
jul/13	578,11	jul/14	745,45	jul/15	839,28	jul/16	920,03	jul/17	1122,11	jul/18	993,78	jul/19	1169,78
ago/13	578,11	ago/14	745,45	ago/15	858,56	ago/16	1021,56	ago/17	1158,14	ago/18	993,11	ago/19	1177,93
set/13	572,63	set/14	828,95	set/15	818,42	set/16	998,33	set/17	1163,56	set/18	1043,30	set/19	1178,71
out/13	572,63	out/14	828,95	out/15	879,42	out/16	1012,80	out/17	1185,95	out/18	880,40	out/19	1144,68
nov/13	497,15	nov/14	740,51	nov/15	825,76	nov/16	964,26	nov/17	1198,90	nov/18	1001,11	nov/19	1101,52
dez/13	498,15	dez/14	740,51	dez/15	820,00	dez/16	1003,62	dez/17	1133,24	dez/18	934,70	dez/19	1036,77

Fonte: Elaborado pelo autor.

A partir desses elementos de tendência representados na Figura 17, os seguintes passos foram executados, adaptado de Hyndman e Athanasopoulos (2018):

. Passo 1 – Escolha de curva de tendência, neste caso, duas curvas de tendência foram escolhidas, gerada no gráfico do Excel, para representar essa série:

a. Polinomial  $Y = 0,0021 x^3 + 0,1509 x^2 + 9,2787 x + 445,12$  (37)

b. Linear  $Y = 8,3956 x + 522,78$  (38)




Figura 17 - Linhas de tendência – Volume de vendas no período - análise exploratória dos dados

Fonte: Elaborado pelo autor.

. Passo 2 – A partir das equações 37 e 38, novas séries de volume (Y) de vendas foram calculados. Nas Tabelas 3 e 4 podemos observar os novos valores projetados representando as duas linhas de tendências escolhidas, a polinomial e a linear.

Tabela 3– Linha de tendência - série polinomial

Serie Polinomial						$Y = 0,0021 x^3 + 0,1509 x^2 + 9,2787 x + 445,12$							
Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume
jan/13	454,55	jan/14	586,63	jan/15	738,59	jan/16	888,64	jan/17	1015,02	jan/18	1095,96	jan/19	1109,68
fev/13	464,26	fev/14	598,84	fev/15	751,47	fev/16	900,38	fev/17	1023,81	fev/18	1099,97	fev/19	1107,10
mar/13	474,26	mar/14	611,17	mar/15	764,32	mar/16	911,94	mar/17	1032,26	mar/18	1103,50	mar/19	1103,90
abr/13	484,51	abr/14	623,61	abr/15	777,13	abr/16	923,31	abr/17	1040,37	abr/18	1106,54	abr/19	1100,05
mai/13	495,02	mai/14	636,15	mai/15	789,89	mai/16	934,48	mai/17	1048,13	mai/18	1109,08	mai/19	1095,55
jun/13	505,77	jun/14	648,78	jun/15	802,59	jun/16	945,43	jun/17	1055,52	jun/18	1111,09	jun/19	1090,38
jul/13	516,74	jul/14	661,49	jul/15	815,21	jul/16	956,15	jul/17	1062,53	jul/18	1112,58	jul/19	1084,52
ago/13	527,93	ago/14	674,25	ago/15	827,75	ago/16	966,64	ago/17	1069,16	ago/18	1113,53	ago/19	1077,98
set/13	539,32	set/14	687,07	set/15	840,18	set/16	976,87	set/17	1075,37	set/18	1113,92	set/19	1070,72
out/13	550,90	out/14	699,93	out/15	852,50	out/16	986,84	out/17	1081,18	out/18	1113,74	out/19	1062,75
nov/13	562,65	nov/14	712,81	nov/15	864,69	nov/16	996,53	nov/17	1086,55	nov/18	1112,98	nov/19	1054,05
dez/13	574,57	dez/14	725,70	dez/15	876,74	dez/16	1005,93	dez/17	1091,48	dez/18	1111,63	dez/19	1044,60

Fonte: Elaborado pelo autor.

Tabela 4 - Linha de tendência - série linear

Serie Linear						$Y = 8,3956 x + 522,78$							
Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume
jan/13	531,18	jan/14	631,92	jan/15	732,67	jan/16	833,42	jan/17	934,16	jan/18	1034,91	jan/19	1135,66
fev/13	539,57	fev/14	640,32	fev/15	741,07	fev/16	841,81	fev/17	942,56	fev/18	1043,31	fev/19	1144,05
mar/13	547,97	mar/14	648,71	mar/15	749,46	mar/16	850,21	mar/17	950,96	mar/18	1051,70	mar/19	1152,45
abr/13	556,36	abr/14	657,11	abr/15	757,86	abr/16	858,60	abr/17	959,35	abr/18	1060,10	abr/19	1160,85
mai/13	564,76	mai/14	665,51	mai/15	766,25	mai/16	867,00	mai/17	967,75	mai/18	1068,49	mai/19	1169,24
jun/13	573,15	jun/14	673,90	jun/15	774,65	jun/16	875,40	jun/17	976,14	jun/18	1076,89	jun/19	1177,64
jul/13	581,55	jul/14	682,30	jul/15	783,04	jul/16	883,79	jul/17	984,54	jul/18	1085,29	jul/19	1186,03
ago/13	589,94	ago/14	690,69	ago/15	791,44	ago/16	892,19	ago/17	992,93	ago/18	1093,68	ago/19	1194,43
set/13	598,34	set/14	699,09	set/15	799,83	set/16	900,58	set/17	1001,33	set/18	1102,08	set/19	1202,82
out/13	606,74	out/14	707,48	out/15	808,23	out/16	908,98	out/17	1009,72	out/18	1110,47	out/19	1211,22
nov/13	615,13	nov/14	715,88	nov/15	816,63	nov/16	917,37	nov/17	1018,12	nov/18	1118,87	nov/19	1219,61
dez/13	623,53	dez/14	724,27	dez/15	825,02	dez/16	925,77	dez/17	1026,52	dez/18	1127,26	dez/19	1228,01

Fonte: Elaborado pelo autor.

. Passo 3 – A média móvel anual centrada de 12 meses foi calculada a partir de série básica original (Apêndice E).

. Passo 4 – Com as médias moveis centradas em 12 meses, foi calculado a média móvel de 2 meses (Apêndice E).

. Passo 5 – Com a média móvel de dois meses foi calculado a média móvel final (Apêndice E).

. Passo 6 – Cálculo do índice sazonal aditivo que é o valor de Y (volume) no período, menos a média móvel final deste período (Apêndice E).

. Passo 7 – Cálculo do índice sazonal multiplicativo que é o valor de Y (volume) no período dividido pela média móvel final deste período (Apêndice E).

. Passo 8 – Cálculo dos índices médios aditivos de sazonalidade do mês corrigidos pelo excesso (Apêndice F).

. Passo 9 – Cálculo dos índices médios multiplicativos de sazonalidade do mês corrigidos pelo excesso (Apêndice F).

. Passo 10 - Cálculo do ciclo e irregularidades da tendência polinomial, para a decomposição aditiva e multiplicativa. No caso aditivo, é o resultado do valor real da série volume menos o valor do volume da série da tendência polinomial menos o índice mensal de sazonalidade. Para o multiplicativo o cálculo é feito dividindo o valor real da série volume pelo produto da série do volume previsto pela

tendência polinomial e multiplicado pelo índice de sazonalidade multiplicativa do mês (Apêndice G).

. Passo 11 - Cálculo do ciclo e irregularidades da tendência linear, para a decomposição aditiva e multiplicativa. No caso aditivo, é o resultado do valor real da série volume menos o valor do volume da série da tendência polinomial menos o índice mensal de sazonalidade. Para o multiplicativo o cálculo é feito dividindo o valor real da série volume pelo produto da série do volume previsto pela tendência linear, multiplicado pelo índice de sazonalidade multiplicativo do mês (Apêndice H).

. Passo 12 – Cálculo da mediana dos ciclos de alta e dos ciclos de baixa separadamente, para a tendência polinomial aditiva e multiplicativa (Apêndice I).

. Passo 13 – Cálculo da mediana dos ciclos de alta e dos ciclos de baixa separadamente, para a tendência linear aditiva e multiplicativa (Apêndice I).

. Passo 14 – Recomposição da tendência polinomial, aditiva e multiplicativa. A aditiva final será a tendência somada ao índice sazonal aditivo e ao ciclo irregular aditivo. A multiplicativa final será o produto da tendência pelo índice sazonal multiplicativo e pelo índice de ciclo irregular multiplicativo (Apêndice J).

. Passo 15 – Recomposição da tendência linear aditiva e multiplicativa. A aditiva final será a tendência somada ao índice sazonal aditivo e ao ciclo irregular aditivo. A multiplicativa final será o produto da tendência linear pelo índice sazonal multiplicativo e pelo índice de ciclo irregular multiplicativo (Apêndice K).

. Passo 16 – Cálculo da acurácia da tendência polinomial corrigida (Apêndice L).

. Passo 17 – Resultado dos indicadores de acurácia, da tendência polinomial corrigida, Error Médio (MAE), Erro Médio Quadrático (MSE), Erro Médio Percentual (MPE) e Erro Percentual Médio (MAPE) (Apêndice M).

. Passo 18 – Cálculo da acurácia da tendência linear corrigida (Apêndice N).

. Passo 19 – Resultado dos indicadores de acurácia da tendência linear corrigida MAE, MSE, MPE e MAPE (Apêndice O).

Podemos observar nos resultados dos indicadores de acurácia (Apêndices M e O) para ambas as tendências, que a recomposição da série através do procedimento multiplicativo, produz uma acurácia menor, porém para efeito comparativo em nosso modelo de rede neural, usaremos as duas decomposições pelo método aditivo e multiplicativo.

### 3.2.3.2 Modelo pela Rede Neural Artificial

Neste estudo foi utilizada uma Rede neural do tipo MLP que tipicamente é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, conforme ilustrada na Figura 12. Neste tipo de rede o treinamento do modelo é supervisionado uma vez que a resposta de saída da rede está sempre disponível.

Para o problema de previsão causal, que é objetivo do estudo, as entradas são as variáveis independentes, tendo a seguinte relação funcional:

$$y = f(x_1, x_2, \dots, x_p), \text{ onde,} \quad (39)$$

$$x_1, x_2, \dots, x_p, \text{ são independentes,} \quad (40)$$

$$y, \text{ é a variável dependente} \quad (41)$$

Em nosso modelo de Rede neural aplicaremos as variáveis apresentadas na Tabela 1:

$$y = \text{VOLUME}$$

$$x_1 = \text{PREÇO}$$

$$x_2 = \text{MÍDIA (investimento em mídia)}$$

$$x_3 = \text{RENDA}$$

$$x_4 = \text{SHARE (participação de mercado do produto)}$$

A escolha do número de camadas ocultas para a rede é uma tarefa crucial e complicada, porém a maneira ainda mais comum é pela tentativa e erro, porém segundo Zhang, Patuwo e Hu (1998), utilizando uma camada, muitas vezes, é possível ter um bom resultado.

O desenvolvimento do presente modelo em Rede Neural, cujo roteiro simplificado do código representado na Figura 18, teve as seguintes características:

- a. Software Python, versão 3.7;
- b. Bibliotecas da plataforma aberta ao público “Sklearn”;
- c. Quantidade de Camadas ocultas utilizadas - 1;
- d. Quantidade de Neurônios na camada oculta – 16;
- e. Quantidade de Neurônio de saída - 1;
- f. Função de Ativação da camada de saída – Tangente Hiperbólica.

<b>Roteiro simplificado do código</b>	
1. Carrega biblioteca	
2. Define função MAPE	
3. Define função RMSE	
4. Define lista de nomes das variáveis independentes	
5. Define nome da variável dependente	
6. Define as métricas de acurácia	
7. Monta a lista das combinações	
8. Carrega dados	
9. Define conjunto das métricas	
10. Para métrica nas métricas	
11. Estabelece conjunto das métricas médias de treinamento	
12. Estabelece conjunto das métricas desvios de treinamento	
13. Estabelece conjunto das métricas médias de validação	
14. Estabelece conjunto das métricas desvios de validação	
16. Estabelece conjunto das métricas médias de teste	
15. Estabelece conjunto das métricas médias de teste	
16. Para lista de combinações e modelos	
17. Imprime a combinação e modelo	
18. Define conjunto das variáveis independentes	
19. Define conjunto da variável dependente	
20. Separa dados em treino, validação e teste	
21. Faz normalização dos dados da variável independente	
22. Faz normalização da variável dependente	
23. Para métrica nas métricas	
24. Estabelece conjunto de resultados de treinamento	
25. Estabelece conjunto de resultados de validação	
26. Estabelece conjunto de resultados de teste	
27. Se modelo é MLP	
28. Usar 16 neurônios, 1 camada, função tangente hiperbólica	
29. Se modelo é Linear	
29. Usar 1 neurônios, 1 camada, função tangente hiperbólica	
30. Compila modelo	
31. Paralisa processo com menor MAE	
32. Salva modelo com menor MAE	
33. Ajusta o modelo	
34. Carrega o melhor modelo	
35. Faz previsões para o conjunto de treino. Validação e teste	
36. Plota gráfico para cada combinação	
37. Alimenta tabela excel com as métricas do treino, validação e teste	

Figura 18 - Roteiro simplificado do código



O software contendo o modelo foi usado para obter as métricas de acurácia considerando a Rede neural e o modelo de regressão, utilizando-se dos seguintes conjuntos de dados:

- Dados originais – Apêndice A;
- Dados contendo o volume dessazonalizado pelo critério **aditivo** usando a função **polinomial** como linha de tendência (Tabela 5);

Tabela 5 – Série polinomial decomposta de forma aditiva

Série Polinomial Decomposição Aditiva												$Y = 0,0021 x^3 + 0,1509 x^2 + 9,2787 x + 445,12$	
Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume
jan/13	412,14	jan/14	544,23	jan/15	607,30	jan/16	846,24	jan/17	883,74	jan/18	1053,55	jan/19	978,39
fev/13	483,11	fev/14	528,80	fev/15	681,43	fev/16	919,23	fev/17	1042,65	fev/18	1118,82	fev/19	1037,07
mar/13	462,65	mar/14	688,44	mar/15	752,71	mar/16	900,33	mar/17	1109,53	mar/18	1180,77	mar/19	1092,29
abr/13	442,95	abr/14	670,92	abr/15	735,57	abr/16	881,74	abr/17	1087,69	abr/18	1153,86	abr/19	1058,49
mai/13	520,77	mai/14	573,01	mai/15	726,76	mai/16	871,34	mai/17	1073,87	mai/18	1134,82	mai/19	1032,41
jun/13	481,81	jun/14	624,82	jun/15	778,63	jun/16	921,47	jun/17	1120,44	jun/18	1176,01	jun/19	1066,41
jul/13	578,11	jul/14	722,85	jul/15	876,58	jul/16	928,64	jul/17	1123,90	jul/18	1085,06	jul/19	1145,89
ago/13	608,42	ago/14	754,74	ago/15	819,35	ago/16	1047,12	ago/17	1149,64	ago/18	1105,13	ago/19	1158,46
set/13	534,71	set/14	771,34	set/15	835,57	set/16	972,26	set/17	1159,64	set/18	1109,30	set/19	1154,99
out/13	615,98	out/14	765,01	out/15	917,58	out/16	1051,92	out/17	1146,26	out/18	1089,94	out/19	1127,84
nov/13	509,40	nov/14	748,43	nov/15	811,44	nov/16	943,28	nov/17	1122,18	nov/18	1059,73	nov/19	1089,68
dez/13	497,88	dez/14	737,90	dez/15	800,06	dez/16	1018,13	dez/17	1103,68	dez/18	1034,95	dez/19	1056,80

Fonte: Elaborado pelo autor.

- Dados contendo o volume dessazonalizado pelo critério **multiplicativo** usando a função **polinomial** como linha de tendência (Tabela 6);

Tabela 6 – Série polinomial decomposta de forma multiplicativa

Série Polinomial Decomposição Multiplicativa												$Y = 0,0021 x^3 + 0,1509 x^2 + 9,2787 x + 445,12$	
Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume
jan/13	427,64	jan/14	551,90	jan/15	619,88	jan/16	836,03	jan/17	851,89	jan/18	1031,08	jan/19	931,32
fev/13	470,23	fev/14	541,07	fev/15	678,98	fev/16	911,94	fev/17	1036,95	fev/18	1114,10	fev/19	1000,31
mar/13	454,32	mar/14	656,29	mar/15	732,18	mar/16	873,59	mar/17	1108,47	mar/18	1184,98	mar/19	1057,48
abr/13	453,98	abr/14	654,99	abr/15	728,15	abr/16	865,12	abr/17	1092,72	abr/18	1162,22	abr/19	1030,72
mai/13	493,13	mai/14	565,33	mai/15	701,95	mai/16	930,90	mai/17	1044,11	mai/18	1104,83	mai/19	973,58
jun/13	533,63	jun/14	610,65	jun/15	755,42	jun/16	889,86	jun/17	1113,66	jun/18	1172,30	jun/19	1150,44
jul/13	557,37	jul/14	713,49	jul/15	784,41	jul/16	920,03	jul/17	1146,07	jul/18	1070,55	jul/19	1169,78
ago/13	584,05	ago/14	745,92	ago/15	816,91	ago/16	953,98	ago/17	1182,80	ago/18	1098,95	ago/19	1192,55
set/13	580,60	set/14	739,66	set/15	806,89	set/16	938,16	set/17	1157,69	set/18	1069,78	set/19	1152,68
out/13	597,07	out/14	758,60	out/15	824,25	out/16	954,14	out/17	1171,80	out/18	1076,83	out/19	1151,83
nov/13	517,91	nov/14	735,50	nov/15	795,93	nov/16	917,29	nov/17	1121,14	nov/18	1024,48	nov/19	1087,60
dez/13	514,61	dez/14	728,60	dez/15	785,26	dez/16	1009,95	dez/17	1095,85	dez/18	995,64	dez/19	1048,78

Fonte: Elaborado pelo autor.

- Dados contendo o volume dessazonalizado pelo critério **aditivo** usando a função **linear** como linha de tendência (Tabela 7);

Tabela 7- Série linear decomposta de forma aditiva

Serie Linear Decomposição Aditiva						$Y = 8,3956x + 522,78$					
Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume
jan/13	532,40	jan/14	470,58	jan/15	571,33	jan/16	834,64	jan/17	935,39	jan/18	1036,14
fev/13	439,48	fev/14	540,23	fev/15	640,98	fev/16	904,29	fev/17	1005,04	fev/18	1105,78
mar/13	506,31	mar/14	607,05	mar/15	707,80	mar/16	971,11	mar/17	1071,86	mar/18	1172,61
abr/13	484,74	abr/14	585,49	abr/15	686,24	abr/16	786,99	abr/17	1050,30	abr/18	1151,05
mai/13	471,57	mai/14	572,32	mai/15	673,06	mai/16	936,38	mai/17	1037,12	mai/18	1137,87
jun/13	519,14	jun/14	619,89	jun/15	720,63	jun/16	983,95	jun/17	1084,69	jun/18	1185,44
jul/13	523,98	jul/14	787,29	jul/15	888,04	jul/16	988,79	jul/17	1089,53	jul/18	1027,71
ago/13	551,49	ago/14	814,81	ago/15	915,55	ago/16	1016,30	ago/17	1117,05	ago/18	1055,23
set/13	563,67	set/14	826,99	set/15	765,17	set/16	1028,48	set/17	1129,23	set/18	1067,41
out/13	552,89	out/14	816,20	out/15	916,95	out/16	1017,69	out/17	1118,44	out/18	1056,62
nov/13	531,83	nov/14	795,14	nov/15	895,89	nov/16	996,63	nov/17	1097,38	nov/18	1035,56
dez/13	516,79	dez/14	780,11	dez/15	880,85	dez/16	981,60	dez/17	1082,35	dez/18	1020,53

Fonte: Elaborado pelo autor.

- e. Dados contendo o volume dessazonalizado pelo critério **multiplicativo** usando a função **linear** como linha de tendência (Tabela 8);

Tabela 8 - Série linear decomposta de forma multiplicativa

Serie Linear Decomposição Multiplicativa						$Y = 8,3956x + 522,78$					
Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume
jan/13	436,58	jan/14	519,39	jan/15	602,20	jan/16	819,24	jan/17	918,28	jan/18	1017,31
fev/13	477,44	fev/14	566,59	fev/15	655,74	fev/16	890,86	fev/17	997,48	fev/18	1104,10
mar/13	514,07	mar/14	608,59	mar/15	703,10	mar/16	953,93	mar/17	1066,97	mar/18	1180,00
abr/13	510,52	abr/14	602,97	abr/15	695,41	abr/16	787,86	abr/17	1052,82	abr/18	1163,38
mai/13	491,50	mai/14	579,18	mai/15	797,55	mai/16	902,41	mai/17	1007,27	mai/18	1112,14
jun/13	528,31	jun/14	621,18	jun/15	853,97	jun/16	965,04	jun/17	1076,10	jun/18	1187,16
jul/13	548,01	jul/14	768,94	jul/15	882,48	jul/16	996,02	jul/17	1109,56	jul/18	1022,69
ago/13	570,18	ago/14	798,37	ago/15	914,83	ago/16	1031,28	ago/17	1147,74	ago/18	1057,04
set/13	562,75	set/14	786,35	set/15	752,26	set/16	1013,00	set/17	1126,32	set/18	1036,52
out/13	574,50	out/14	801,17	out/15	915,26	out/16	1029,35	out/17	1143,44	out/18	1051,47
nov/13	554,51	nov/14	771,80	nov/15	880,41	nov/16	989,03	nov/17	1097,64	nov/18	1008,60
dez/13	546,92	dez/14	759,78	dez/15	865,47	dez/16	971,16	dez/17	1076,84	dez/18	988,76

Fonte: Elaborado pelo autor.

- f. Dados originais agregando um indicador de **tendência bimestral** (valor dado original menos valor da média móvel bimestral, calculo conforme apresentado no Apêndice 15) entrando no modelo como mais uma variável independente causal (Tabela 9).

Tabela 9- Série indicadora de tendência de 2 períodos

Serie Indicador Diferença 2 Períodos											
Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume
jan/13		jan/14	42,58	jan/15	-124,58	jan/16	9,80	jan/17	-98,40	jan/18	-88,15
fev/13		fev/14	21,04	fev/15	-30,02	fev/16	61,11	fev/17	81,57	fev/18	36,92
mar/13	-21,94	mar/14	107,02	mar/15	83,05	mar/16	60,71	mar/17	138,18	mar/18	158,12
abr/13	-10,97	abr/14	53,51	abr/15	68,28	abr/16	-68,17	abr/17	20,31	abr/18	-42,03
mai/13	74,60	mai/14	-48,12	mai/15	1,44	mai/16	24,52	mai/17	-42,00	mai/18	1,17
jun/13	37,30	jun/14	-24,06	jun/15	45,25	jun/16	27,98	jun/17	71,42	jun/18	25,07
jul/13	60,82	jul/14	146,31	jul/15	78,70	jul/16	19,90	jul/17	32,41	jul/18	-222,37
ago/13	30,41	ago/14	73,15	ago/15	45,32	ago/16	112,85	ago/17	29,98	ago/18	-111,42
set/13	-5,47	set/14	83,50	set/15	-30,50	set/16	27,54	set/17	23,43	set/18	49,86
out/13	-2,74	out/14	41,75	out/15	40,93	out/16	2,86	out/17	25,10	out/18	-137,81
nov/13	-75,48	nov/14	-88,44	nov/15	-23,16	nov/16	-41,31	nov/17	24,15	nov/18	39,26
dez/13	-36,74	dez/14	-44,22	dez/15	-32,59	dez/16	-44,22	dez/17	-59,19	dez/18	-6,06

Fonte: Elaborado pelo autor.

- g. Dados originais agregando um indicador de tendência **trimestral** (valor original menos valor da média móvel bimestral, calculo conforme apresentado Apendice 15) entrando no modelo como mais uma variável causal (Tabela 10).

Tabela 10 - Série indicadores de tendência de 3 períodos

Serie Indicador Diferença 3 Períodos													
Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume	Mês	Volume
jan/13		jan/14	17,59	jan/15	-154,06	jan/16	-9,05	jan/17	-108,02	jan/18	-94,78	jan/19	-39,18
fev/13		fev/14	28,39	fev/15	-50,78	fev/16	61,30	fev/17	75,01	fev/18	5,81	fev/19	79,36
mar/13		mar/14	121,05	mar/15	46,90	mar/16	74,07	mar/17	122,25	mar/18	150,44	mar/19	71,41
abr/13	-14,62	abr/14	71,35	abr/15	90,18	abr/16	-44,35	abr/17	78,49	abr/18	0,46	abr/19	79,48
mai/13	67,29	mai/14	-12,44	mai/15	29,55	mai/16	21,49	mai/17	-21,65	mai/18	25,63	mai/19	-76,47
jun/13	49,74	jun/14	-32,08	jun/15	54,19	jun/16	10,85	jun/17	61,01	jun/18	-0,98	jun/19	92,52
jul/13	85,69	jul/14	130,27	jul/15	82,25	jul/16	41,29	jul/17	35,51	jul/18	-204,78	jul/19	126,09
ago/13	40,55	ago/14	97,54	ago/15	71,75	ago/16	114,79	ago/17	57,63	ago/18	-148,92	ago/19	98,40
set/13	14,80	set/14	132,27	set/15	-9,92	set/16	52,00	set/17	25,41	set/18	-24,09	set/19	26,72
out/13	-3,65	out/14	55,67	out/15	40,67	out/16	32,83	out/17	38,01	out/18	-129,66	out/19	-30,79
nov/13	-77,31	nov/14	-60,60	nov/15	-26,37	nov/16	-46,64	nov/17	29,68	nov/18	28,84	nov/19	-65,59
dez/13	-49,32	dez/14	-58,96	dez/15	-21,20	dez/16	-58,96	dez/17	-49,56	dez/18	-40,24	dez/19	-104,86

Fonte: Elaborado pelo autor.

Todas as sete bases de dados mencionadas acima foram submetidas ao código desenvolvido em Python, com algoritmos em Rede Neural e modelos de Regressão Linear, a fim de avaliar se houve algum impacto do processo de decomposição sazonal na melhoria de acurácia da previsão. Há autores que indicam o uso dos dados puros sem o procedimento de decomposição, para que todos os efeitos do comportamento original da série sejam percebidos pelo modelo (DE GOOIJER; FRANSES, 1997).

Ao nível de produto vários fatores podem afetar os dados de volume de vendas, alguns desses fatores são parte inerente da composição dos diversos tipos de itens da mesma categoria no ponto de venda, tais como promoções de preço, produtos substitutos ou produtos complementares. Outros fatores como feriados festivos, estações do ano, férias escolares e eventos esportivos também afetam a os dados de volume de vendas. A renda média do consumidor tem um papel importante no consumo de alimentos segundo De Angelo et al. (2011), e o crescimento da renda favorece o aumento de consumo no varejo.

Neste estudo foram testadas todas as combinações possíveis para cada uma das variáveis independentes causais definidas: PREÇO, MÍDIA, RENDA e SHARE, resultando em um conjunto de quinze testes para o modelo em Rede Neural,

tipo MLP, e quinze testes para o modelo de regressão linear, totalizando para cada uma das sete séries de dados, trinta testes.

Dentre esses trinta testes de cada série, os dez melhores resultados foram escolhidos, através das medidas de acurácia definidas.

Esses grupos de dados, também foram submetidos ao modelo de regressão disponibilizado pelo software Excel a fim de compará-los aos resultados gerados pelo código em Python.

#### **4. RESULTADOS E DISCUSSÕES**

A previsão de demanda de alimentos é uma área pouco coberta na literatura de Redes neurais, embora algumas grandes redes de supermercados utilizem pacotes de software de previsão de demanda (TSOUMAKAS, 2019).

A demanda e as atividades relacionadas exigem volume de dados nem sempre disponível, a integração com parceiros na cadeia de suprimentos e também uma atenção aos níveis de acurácia da demanda projetada (TAYLOR; FEARNE, 2009).

Em pesquisa sobre escolha e uso de métodos para previsão de demanda nas indústrias brasileiras, as variáveis: tipo de produto e tempo despendido são as que mais influenciam na decisão sobre o método segundo Cecatto e Belfiore. (2015).

Tendo em vista essas considerações foi utilizado no presente estudo o conjunto de dados das séries temporais descritas no item anterior para testar o modelo desenvolvido.

Como resultado adjacente a este estudo foi gerada uma aplicação para simulação de previsão em Python, que permite o uso de um conjunto de variáveis causais independentes e de fácil utilização.

A Tabela 11 apresenta os principais resultados das sete séries estudadas, com suas respectivas melhores combinações das variáveis causais: “RENTA”, “MÍDIA”, “RENTA”, “SHARE”, utilizadas no modelo de Rede neural, tipo MLP. Observa-se que os dois melhores resultados, foram originados com a decomposição da série original, usando uma tendência polinomial.

Tabela 11 - Os melhores resultados de cada um dos modelos

Séries utilizadas	Combinações	Modelo	R2	MSE	RMSE	MAE	MAPE
Série Polinomial decomposta de forma aditiva	PRECIO, MIDIA, RENTA, SHARE	MLP	0,893	3016,838	54,909	44,411	4,270
Série Polinomial decomposta de forma multiplicativa	PRECIO, MIDIA, RENTA, SHARE	MLP	0,877	3754,999	61,160	50,688	4,804
Série Indicador diferença 3 períodos média movel	PRECIO, MIDIA, RENTA, SHARE	MLP	0,865	3941,972	62,778	51,944	4,906
Série Indicador diferença 2 períodos média movel	PRECIO, MIDIA, RENTA, SHARE, DIFM2	MLP	0,863	3997,617	62,904	55,785	5,523
Série Original	PRECIO, MIDIA, RENTA, SHARE	MLP	0,862	4034,175	63,507	53,444	5,073
Série Linear decomposta de forma aditiva	MIDIA, RENTA, SHARE	MLP	0,852	3228,345	56,790	48,040	4,633
Série Linear decomposta de forma multiplicativa	MIDIA, RENTA, SHARE	MLP	0,850	2951,450	54,281	44,526	4,334
Média		MLP	0,866	3560,771	59,476	49,834	4,792

Fonte: Elaborado pelo autor.

Segundo De Gooijer e Franses (1997), embora os ajustes de sazonalidade muitas vezes possam ser úteis, recomenda-se o uso de dados sem utilizar o processo de decomposição, pois pode-se levar a uma distorção das propriedades de tendência, sazonalidade, ciclos e irregularidades.

A Tabela 12 apresenta o resultado de melhor combinação das variáveis causais do modelo linear em Python, e mostra que o processo de decomposição usando a tendência polinomial linear acrescenta uma pequena melhora da correlação e da acurácia do modelo.

Tabela 12- Os melhores resultados do modelo linear dentre os 10 melhores de cada série utilizadas

Séries utilizadas	Combinações	Modelo	R2	MSE	RMSE	MAE	MAPE
Série Polinomial decomposta de forma aditiva	PRECO, MIDIA, RENDA, SHARE	Linear	0,851	4192,573	64,742	52,144	4,867
Série Polinomial decomposta de forma multiplicativa	PRECO, MIDIA, SHARE	Linear	0,831	5144,502	71,723	57,979	5,347
Série Indicador diferença 3 períodos média movel	PRECO, MIDIA, RENDA, SHARE	Linear	0,828	5019,073	70,840	54,634	5,110
Série Original	PRECO, MIDIA, RENDA, SHARE	Linear	0,824	5127,129	71,593	55,155	5,147
Série Linear decomposta de forma aditiva	PRECO, MIDIA, RENDA, SHARE	Linear	0,771	4985,331	70,500	59,219	5,817
Série Linear decomposta de forma multiplicativa	MIDIA, RENDA, SHARE	Linear	0,747	4971,594	70,508	60,167	6,000
	Média	Linear	0,809	4906,700	69,984	56,550	5,381

Fonte: Elaborado pelo autor.

Considerando os resultados mostrados nas Tabelas 11 e 12 e as respectivas médias dos indicadores de acurácia, os modelos em Rede neural, tipo MLP, tiveram um desempenho melhor em relação ao linear (Tabelas 13).

Tabela 13- Comparativo de desempenho médio dos indicadores de acurácia

Acuracia Média dos Modelos	Modelo	R2	MSE	RMSE	MAE	MAPE
Média	MLP	0,867	3531,931	59,221	49,070	4,740
Média	Linear	0,807	4950,353	70,289	56,944	5,423
Diferença		7,4%	-28,7%	-15,7%	-13,8%	-12,6%

Fonte: Elaborado pelo autor.

Essa diferença entre o método em Rede neural do tipo MPL e entre modelo linear se torna considerável, em se tratando de grandes volumes de produção.

As Tabelas 14 a 20 apresentam os 10 melhores resultados de cada série de dados.

Tabela 14– Os 10 melhores resultados usando a **série de dados originais**

Combinações	Modelo	R2	MSE	RMSE	MAE	MAPE
PRECO, MIDIA, RENDA, SHARE	MLP	0,8618	4034,1752	63,5073	53,4440	5,0730
PRECO, RENDA, SHARE	MLP	0,8610	4058,4639	63,7055	52,6416	4,9816
PRECO, SHARE	MLP	0,8514	4338,2194	65,8102	53,7888	5,1478
MIDIA, RENDA, SHARE	MLP	0,8439	4557,9557	67,4632	56,9896	5,4203
PRECO, MIDIA, SHARE	MLP	0,8414	4630,4589	67,9963	57,4076	5,5432
PRECO, MIDIA, RENDA, SHARE	Linear	0,8244	5127,1286	71,5931	55,1552	5,1467
PRECO, SHARE	Linear	0,8185	5298,2363	72,7817	56,0134	5,1871
PRECO, RENDA, SHARE	Linear	0,8171	5340,1246	73,0759	56,0649	5,2114
PRECO, MIDIA, SHARE	Linear	0,8094	5562,5234	74,5724	58,2052	5,4378
RENDA, SHARE	MLP	0,7987	5877,1232	76,6417	63,0242	5,9274
Média	MLP	0,843	4582,733	67,521	56,216	5,349
	Linear	0,817	5332,003	73,006	56,360	5,246

Fonte: Elaborado pelo autor.

Tabela 15- Os 10 melhores resultados usando a **série polinomial** decomposta de forma aditiva

Combinações	Modelo	R2	MSE	RMSE	MAE	MAPE
PRECO, MIDIA, RENDA, SHARE	MLP	0,893	3016,838	54,909	44,411	4,270
PRECO, MIDIA, SHARE	MLP	0,889	3134,701	55,944	46,072	4,458
PRECO, RENDA, SHARE	MLP	0,883	3283,238	57,278	47,336	4,521
MIDIA, RENDA, SHARE	MLP	0,875	3511,513	59,095	49,563	4,757
PRECO, SHARE	MLP	0,873	3573,823	59,746	49,577	4,839
MIDIA, RENDA	MLP	0,856	4052,162	63,654	48,925	4,909
PRECO, MIDIA, RENDA	MLP	0,851	4185,556	64,633	51,288	5,446
PRECO, MIDIA, RENDA, SHARE	Linear	0,851	4192,573	64,742	52,144	4,867
PRECO, MIDIA, SHARE	Linear	0,837	4569,377	67,596	55,417	5,177
PRECO, RENDA	MLP	0,835	4648,914	68,182	55,773	6,051
Média	MLP	0,869	3675,843	60,430	49,118	4,906
	Linear	0,844	4380,975	66,169	53,781	5,022

Fonte: Elaborado pelo autor.

Tabela 16- Os 10 melhores resultados usando a **série polinomial** decomposta de forma multiplicativa

Combinações	Modelo	R2	MSE	RMSE	MAE	MAPE
PRECO, MIDIA, RENDA, SHARE	MLP	0,877	3754,999	61,160	50,688	4,804
PRECO, MIDIA, SHARE	MLP	0,870	3948,681	62,766	51,258	4,921
PRECO, RENDA, SHARE	MLP	0,866	4061,696	63,586	53,180	5,010
PRECO, MIDIA, RENDA	MLP	0,863	4157,324	64,468	53,726	5,605
PRECO, RENDA	MLP	0,851	4523,584	67,256	56,856	6,039
PRECO, SHARE	MLP	0,851	4524,267	67,212	55,389	5,193
MIDIA, RENDA, SHARE	MLP	0,844	4735,765	68,748	56,382	5,379
PRECO, MIDIA, SHARE	Linear	0,831	5144,502	71,723	57,979	5,347
MIDIA, RENDA	MLP	0,830	5157,939	71,660	55,774	5,481
PRECO, SHARE	Linear	0,825	5335,330	73,037	58,463	5,368
Média	MLP	0,857	4358,032	65,857	54,157	5,304
	Linear	0,828	5239,916	72,380	58,221	5,357

Fonte: Elaborado pelo autor.

Tabela 17- Os 10 melhores resultados usando a **série linear** decomposta de forma aditiva

Combinações	Modelo	R2	MSE	RMSE	MAE	MAPE
MIDIA, RENDA, SHARE	MLP	0,852	3228,345	56,790	48,040	4,633
RENDA, SHARE	MLP	0,819	3938,927	62,487	53,167	5,094
PRECO, MIDIA, SHARE	MLP	0,806	4232,476	65,038	53,346	5,248
PRECO, MIDIA, RENDA, SHARE	MLP	0,796	4444,878	66,658	54,516	5,441
PRECO, SHARE	MLP	0,796	4451,481	66,703	54,874	5,433
MIDIA, RENDA	MLP	0,792	4539,109	67,366	55,268	5,441
PRECO, RENDA, SHARE	MLP	0,786	4657,028	68,237	55,061	5,491
PRECO, MIDIA, RENDA, SHARE	Linear	0,771	4985,331	70,500	59,219	5,817
PRECO, RENDA, SHARE	Linear	0,754	5359,507	73,208	61,839	6,076
PRECO, MIDIA, SHARE	Linear	0,753	5372,897	73,300	61,918	6,074
Média	MLP	0,806	4213,178	64,754	53,467	5,254
	Linear	0,759	5239,245	72,336	60,992	5,989

Fonte: Elaborado pelo autor.

Tabela 18- Os 10 melhores resultados usando a **série linear decomposta de forma multiplicativa**

Combinações	Modelo	R2	MSE	RMSE	MAE	MAPE
MIDIA, RENDA, SHARE	MLP	0,850	2951,450	54,281	44,526	4,334
RENDA, SHARE	MLP	0,813	3671,177	60,589	51,693	5,053
PRECO, SHARE	MLP	0,797	3984,155	63,096	49,958	4,941
PRECO, MIDIA, SHARE	MLP	0,785	4238,589	65,038	52,265	5,168
PRECO, MIDIA, RENDA, SHARE	MLP	0,782	4280,624	65,425	53,199	5,261
MIDIA, RENDA	MLP	0,777	4384,651	66,177	53,507	5,253
PRECO, RENDA, SHARE	MLP	0,774	4439,263	66,606	53,746	5,397
MIDIA, RENDA, SHARE	Linear	0,747	4971,594	70,508	60,167	6,000
PRECO, MIDIA, SHARE	Linear	0,742	5080,909	71,280	59,576	5,898
PRECO, RENDA, SHARE	Linear	0,741	5087,587	71,326	59,557	5,893
Média	MLP	0,781	4309,000	65,433	53,819	5,320
	Linear	0,743	5046,697	71,038	59,767	5,930

Fonte: Elaborado pelo autor.

Tabela 19- Os 10 melhores resultados usando a **série com o indicador da diferença entre valor da série original e da média móvel de dois períodos**

Combinações	Modelo	R2	MSE	RMSE	MAE	MAPE
PRECO, MIDIA, RENDA, SHARE, DIFM2	MLP	0,863	3997,617	62,904	55,785	5,523
PRECO, RENDA, SHARE	MLP	0,854	4267,520	65,326	54,349	5,176
PRECO, SHARE, DIFM2	MLP	0,853	4301,352	65,502	53,276	5,205
PRECO, MIDIA, SHARE	MLP	0,848	4447,010	66,674	56,834	5,595
PRECO, SHARE	MLP	0,847	4455,752	66,750	56,014	5,445
MIDIA, RENDA, SHARE	MLP	0,846	4490,049	66,963	56,911	5,453
PRECO, RENDA, SHARE, DIFM2	MLP	0,845	4530,851	67,096	53,682	5,272
PRECO, MIDIA, SHARE, DIFM2	MLP	0,842	4603,859	67,713	54,339	5,241
PRECO, MIDIA, RENDA, SHARE	MLP	0,842	4619,478	67,874	57,770	5,614
MIDIA, RENDA, SHARE, DIFM2	MLP	0,841	4626,867	67,875	52,302	5,154
Média	MLP	0,848	4434,035	66,468	55,126	5,368
	Linear	0,000	0,000	0,000	0,000	0,000

Fonte: Elaborado pelo autor.

Tabela 20- Os 10 melhores resultados usando a **série com o indicador da diferença entre valor da série original e da média móvel de três períodos**

Combinações	Modelo	R2	MSE	RMSE	MAE	MAPE
PRECO, MIDIA, RENDA, SHARE	MLP	0,865	3941,972	62,778	51,944	4,906
PRECO, RENDA, SHARE	MLP	0,859	4123,531	64,211	52,728	4,975
PRECO, SHARE	MLP	0,848	4445,504	66,672	54,922	5,301
MIDIA, RENDA, SHARE, DIFM3	MLP	0,847	4480,685	66,871	55,173	5,427
PRECO, MIDIA, SHARE	MLP	0,844	4541,340	67,354	55,331	5,291
PRECO, MIDIA, RENDA, SHARE	Linear	0,828	5019,073	70,840	54,634	5,110
MIDIA, RENDA, SHARE	MLP	0,824	5124,460	71,546	60,447	5,813
PRECO, MIDIA, SHARE, DIFM3	MLP	0,822	5182,269	71,887	57,779	5,535
PRECO, MIDIA, SHARE	Linear	0,819	5279,077	72,644	56,773	5,330
PRECO, SHARE	Linear	0,815	5413,227	73,573	56,842	5,288
Média	MLP	0,844	4548,537	67,331	55,475	5,321
	Linear	0,821	5237,126	72,352	56,083	5,243

Fonte: Elaborado pelo autor.



As Figuras 19 e 20 ilustram a comparação de trajetória da demanda a partir dos dados de teste usando as melhores combinações de cada modelo conforme mostrado na Tabela 11. Para facilidade de entendimento dos gráficos, a cada série foi associado um rótulo:

Série Polinomial decomposta de forma aditiva - DEPOAD;

Série Polinomial decomposta de forma multiplicativa - DEPOMU;

Série Indicador diferença 3 períodos média móvel – DIFM3;

Série Indicador diferença 2 períodos média móvel – DIFM2;

Série Original - BASEORIGINAL;

Série Linear decomposta de forma aditiva - DELIAD;

Série Linear decomposta de forma multiplicativa - DELIMU.

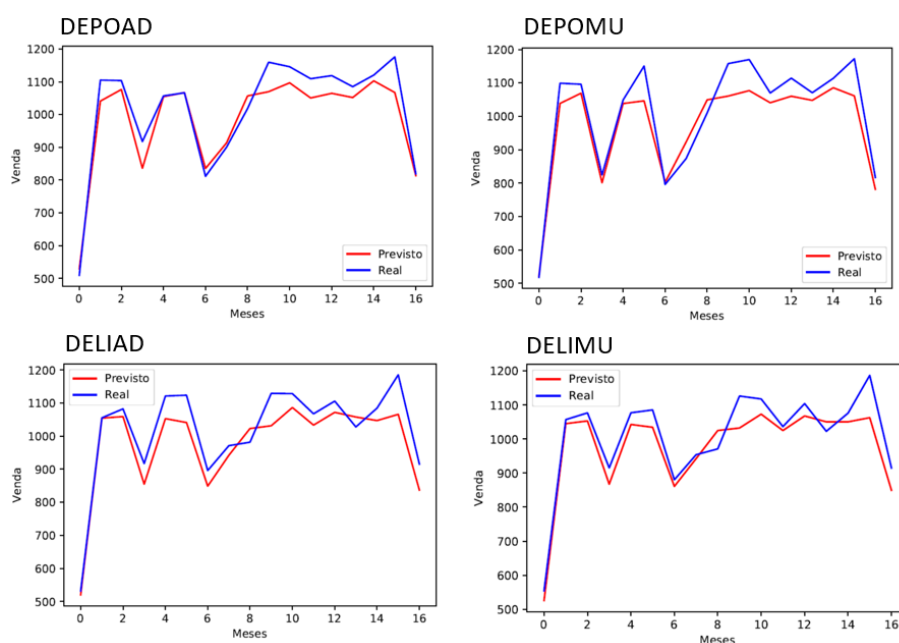


Figura 19- Trajetória prevista comparativa demanda a partir dos dados de teste

Fonte: Elaborado pelo autor.

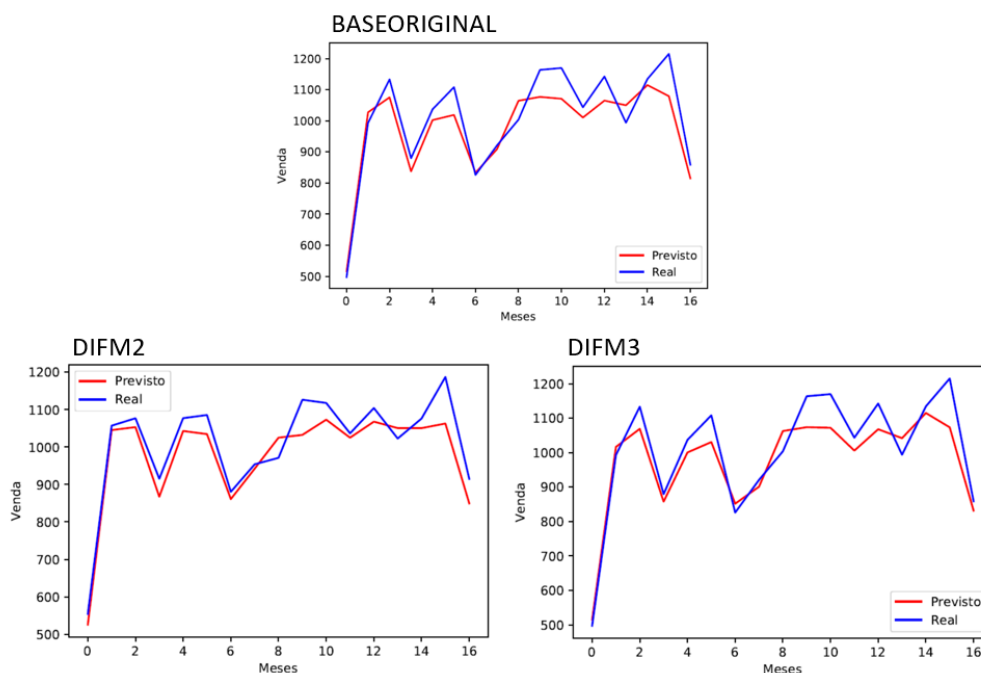


Figura 20- Trajetória prevista comparativa demanda a partir dos dados de teste

Fonte: Elaborado pelo autor.

Como propósito comparativo foi realizado um teste de regressão de cada uma dessas séries, no software Excel da Microsoft (Tabela 21), tendo como resultado níveis próximos aos realizados com os modelos de Rede neural, a Tabela 11 apresenta esses resultados.

Tabela 21- Resultados da regressão realizada em Excel para cada uma das séries

Séries utilizadas	R <sup>2</sup>
Série Polinomial decomposta de forma aditiva	0,887
Série Polinomial decomposta de forma multiplicativa	0,864
Série Indicador diferença 3 períodos média movel	0,862
Série Indicador diferença 2 períodos média movel	0,858
Série Original	0,847
Série Linear decomposta de forma aditiva	0,880
Série Linear decomposta de forma multiplicativa	0,866
Média	0,866

Fonte: Elaborado pelo autor.

Considerando os dados básicos originais da série, somente no ano de 2019, foram vendidas 1074 toneladas médias mensais de produtos.

Os testes dos modelos indicaram que há uma diferença média de erro de previsão entre a abordagem regressão linear e a abordagem Rede Neural, tipo MLP, de 7,4%, considerando o índice de correlação linear ( $R^2$ ).

Com uma **variação média mensal da ordem de 7,4%** por falta ou sobra de produto, que corresponde aproximadamente a 80 (7,4 % x 1074 toneledas) toneladas de produto, a um preço médio de venda no ano de R\$ 32,00/kg, teríamos **perdas** de aproximadamente **R\$ 2.560.000,00** no ano.

Portanto, ter um modelo que reflita as condições operacionais do negócio é fundamental para minimizar as perdas operacionais decorrentes da falta ou sobra de produto nos estoques.

A simulação de possíveis cenários futuros é de grande ajuda para cadeia logística e os modelos de previsão possibilitam este exercício de entender qual é a melhor estratégica operacional a seguir.

Tendo isso como premissa de sobrevivência nesse competitivo mercado de varejo de alimentos, usaremos o modelo que nos forneceu a melhor performance em termos do índice de correlação ( $R^2$ ), para simular um possível cenário futuro com as variáveis causais e saber qual será o volume de venda nos próximos meses.

A Tabela 17 mostra como melhor resultado a série “polinomial decomposta de forma aditiva”, que será usada para treinar nosso modelo e fazer a previsão.

Quanto as variáveis causais, construímos um cenário para os próximos meses baseados no perfil de dados de 2019 e considerando os seguintes aumentos ou diminuição das variáveis causais (Tabela 22).

Tabela 22- Premissas de cenário para simulação

CENÁRIO PARA SIMULAÇÃO				
ANO	PREÇO	MÍDIA	RENDIA	SHARE
2020	5%	-30%	0%	-10%
2021	8%	-20%	3%	-15%
2022	15%	-15%	5%	-10%

Fonte: Elaborado pelo autor

Aplicando essas variações, nas variáveis causais em nosso melhor modelo, que é a “Série Polinomial decomposta de forma aditiva – DEPOAD”, teremos os seguintes volumes previstos para os anos de 2020, 2021 e 2022 (Tabela 23).

Tabela 23 - Volume previsto para os anos 2020, 2021 e 2022 usando a série DEPOAD

Previsão de volume de venda usando série DEPOAD					
jan/20	1043,76	jan/21	1025,05	jan/22	1037,67
fev/20	1049,52	fev/21	1023,91	fev/22	1047,74
mar/20	1038,98	mar/21	1016,50	mar/22	1041,59
abr/20	1029,09	abr/21	1031,35	abr/22	1057,02
mai/20	1017,34	mai/21	1023,52	mai/22	1050,92
jun/20	1003,81	jun/21	1009,36	jun/22	1037,77
jul/20	1050,60	jul/21	1036,40	jul/22	1062,32
ago/20	1049,86	ago/21	1035,01	ago/22	1060,25
set/20	1037,68	set/21	1024,49	set/22	1052,07
out/20	1025,57	out/21	1013,82	out/22	1043,42
nov/20	1011,85	nov/21	1001,69	nov/22	1034,03
dez/20	1016,77	dez/21	996,86	dez/22	1036,38

Fonte: Elaborado pelo autor

O comportamento da previsão usando a série DEPOAD para os anos 2020, 2021 e 2022 em relação aos anos anteriores é mostrado na Figura 21.




Figura 21 - Volume previsto de 2020 a 2022 como resultado da simulação de cenário usando a “Série Polinomial decomposta de forma aditiva – DEPOAD”.

Fonte: Elaborado pelo autor

A fim de comparar os efeitos da decomposição no modelo de previsão, foi gerado uma previsão usando a “Série Original – BASEORIGINAL”, para treinar o

modelo, resultando nos seguintes volumes previstos para os anos de 2020, 2021 e 2022 (Tabela 24).

Tabela 24- Volume previsto para os anos 2020, 2021 e 2022 usando a série BASEORIGINAL

Previsão de volume de venda usando série BASEORIGINAL					
jan/20	974,58	jan/21	933,25	jan/22	955,07
fev/20	994,46	fev/21	940,83	fev/22	977,39
mar/20	973,28	mar/21	916,48	mar/22	960,30
abr/20	961,14	abr/21	927,48	abr/22	968,12
mai/20	921,35	mai/21	885,29	mai/22	930,15
jun/20	927,47	jun/21	894,23	jun/22	938,42
jul/20	986,44	jul/21	948,21	jul/22	987,23
ago/20	986,18	ago/21	948,24	ago/22	985,87
set/20	965,04	set/21	927,55	set/22	967,65
out/20	943,61	out/21	906,75	out/22	948,36
nov/20	921,49	nov/21	885,78	nov/22	928,56
dez/20	922,79	dez/21	865,03	dez/22	928,25

Fonte: Elaborado pelo autor

O comportamento da previsão usando a série BASEORIGINAL para os anos 2020, 2021 e 2022 em relação aos anos anteriores é mostrado na Figura 22.




Figura 22- Volume previsto de 2020 a 2022 como resultado da simulação de cenário usando as séries DEPOAD e BASEORIGINAL.

Fonte: Elaborado pelo autor

Podemos observar que a previsão gerada a partir da “Série Polinomial decomposta de forma aditiva – DEPOAD” apresenta uma linearidade mais constante em relação a previsão gerada a partir da “Série Original – BASEORIGINAL”, que não foi decomposta, isso indicada que o uso da decomposição reduz as variações provocada pelos efeitos da tendência, ciclos e irregularidades.

A Figura 23 mostra com mais detalhes o comparativo das previsões feitas a partir destas duas series, “Série Polinomial decomposta de forma aditiva – DEPOAD” e “Série Original – BASEORIGINAL”.




Figura 23– Comparativo entre as séries DEPOAD e BASEORIGINAL de volume previsto de 2020 a 2022 usando o cenário de simulação.

## 5. CONSIDERAÇÕES FINAIS

No contexto econômico atual, de grandes incertezas e constantes mudanças, ter uma visão mais clara de que caminho seguir, torna-se crucial para a sobrevivência e performance dos negócios. A indústria de alimentos, inserida neste ambiente e pelo que significa em termos econômicos e de geração de emprego, precisa de processos e sistemas de alerta e monitoramento cada vez mais rápidos e de fácil compreensão, para uma gestão operacional eficaz.

Em pesquisa sobre uso de métodos para previsão de demanda na indústria alimentícia foi identificado que o atributo, tipo de produto e a facilidade do uso do método são os elementos mais considerados para decidir qual técnica deveria ser escolhida (CECATTO; BELFIORE, 2015).

Segundo Tsoumakas (2019), o tema de previsão na indústria de alimentos não é muito coberto na literatura de aprendizagem de máquinas - “machine learning”.

O estudo realizado de previsão de demanda, de um produto alimentício específico, vem de encontro com as essas necessidades cada vez mais prementes de antever o que produzir e quando, com a menor incerteza possível.

As ações de mercado para vender o produto através de promoções, descontos e publicidade são atividades constantes do setor de alimentos que afetam a demanda dos produtos e acirra a competição entre os fabricantes.

A partir de um conjunto de dados reais de mercado, de volume de vendas (VOLUME), preço (PREÇO), investimento em mídia (MÍDIA), renda média (RENDA) e participação de mercado do produto (SHARE) do produto, foi desenvolvido um modelo de previsão em Rede Neural e um modelo de correlação linear que foram testados com sete tipos de séries temporais elaboradas a partir dos dados originais de volume de vendas.

Todas as combinações possíveis das variáveis independentes causais foram feitas e testadas para cada uma das sete séries de dados, gerando, trinta



combinações, quinze combinações para o modelo Rede Neural, tipo MLP, e quinze combinações para o modelo de regressão linear.

Para o propósito de entendimento e estudo com dados reais, foram usadas a decomposição aditiva e a multiplicativa no sentido de verificar a influência desse método no resultado final de acurácia do modelo, usando como base, duas linhas de tendência, uma com característica polinomial e outra com característica linear. As duas equações das linhas de tendência foram decompostas pelo critério aditivo e multiplicativo, obtendo quatro séries para testes acurácia em nosso modelo.

Duas outras séries foram criadas a partir da série básica de volume de venda, que é o que denominamos de “indicador de média móvel” (Apêndice O). Uma série baseada na média móvel bimestral e outra na média móvel trimestral. Essas séries foram geradas a partir da diferença do valor real original da série de volume de vendas em um determinado mês menos o valor da média móvel daquele mês, gerando um número, positivo ou negativo, que chamamos de “indicador de média móvel”, que entrou para o modelo como uma variável independente causal independente junto com as demais (PREÇO, MÍDIA, RENDA e SHARE).

Portanto testamos sete séries temporais em nosso modelo, um primeiro que chamamos de original e as demais geradas pelos métodos retro citados.

Nosso estudo teve três propósitos básicos:

- . Primeiro, investigar qual é a melhor combinação das variáveis independentes causais que gera o modelo com menor erro e previsão;
- . Segundo, nosso método procurou trabalhar com informações reais disponíveis sem incorrer em novos custos para obter informação;
- . Terceiro, o modelo desenvolvido, visou a facilidade de uso, não dependente de um grande esforço ou conhecimento para operá-lo, pois segundo Cecatto e Belfiore (2015) a facilidade de operação é preponderante para o uso de ferramentas de previsão por parte das empresas de alimentos.

Muitos pesquisadores sugerem que uma Rede Neural, pode ter uma boa performance quando comparados com a regressão múltipla, mas não

necessariamente superior. Há limitações na regressão múltiplas que são superadas pela Rede Neural. Essas limitações são (UYSAL; EL ROUBI, 1999):

- . A complexidade da regressão múltipla é limitada pela combinação linear das variáveis;

- . Os modelos de Rede neural não são muito suscetíveis a problemas de especificação como é o caso da regressão múltipla;

- . A Rede Neural pode transformar os dados automaticamente, o que não é o caso da regressão múltipla;

- . Os modelos de Rede neural podem lidar com a não linearidade dos dados através das suas funções de ativação.

O estudo mostrou que os modelos de Rede neural, tipo ML foram superiores aos modelos de regressão linear em 7,4% na média em relação ao índice de correlação  $R^2$ .

Considerando os volumes médios vendidos em 2019, de nossa série original, esse erro de previsão poderia significar uma perda financeira de aproximadamente R\$2,5 milhões.

Em se tratando de um setor cujas indústrias entregam diariamente milhares de toneladas de alimentos, essa diferença média de 7,4% torna-se um número considerável.

Com relação ao tipo de série utilizada, nosso estudo mostrou que o uso prévio da decomposição dos dados teve uma pequena influência positiva nos resultados de acurácia do modelo, sendo o modelo “Série polinomial decomposta de forma aditiva” que obteve o melhor resultado de acurácia com  $R^2$  de 0,893, sendo o modelo polinomial multiplicativo em segundo lugar.

O uso da série com o indicador de média móvel de 3 meses e 2 meses, foram superiores aos dados originais, o que mostra que ao criar esses indicadores e inseri-los juntos as variáveis causais, houve um efeito positivo para a acurácia do modelo.

O modelo com os dados originais apresentou  $R^2$  de 0,862, que não é totalmente descartável, pois ainda assim foi superior aos modelos das duas séries lineares decompostas.

Portanto, como resultado final recomendamos o uso do modelo de previsão em Rede neural, tipo MLP, para previsão de demanda deste tipo de produto alimentício, com diversas variáveis causais.

As complexidades desse mercado de varejo de alimentos impõem outras considerações que poderão ser agregadas ao modelo futuramente, tais como, promoções comerciais em datas festivas nacionais ou regionais, ações específicas de baixas de preços, e novos produtos concorrentes entrantes, acarretando uma complexidade maior ao modelo, porém que seriam úteis a realidade deste mercado.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

ANTHONY, R. N. **Planning and Control Systems: A Framework for Analysis.**

Cambridge: Harvard University Press, 1965. 180 p.

ARUNRAJ, N. S.; AHRENS, D. A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. **International Journal of Production Economics**, [S.l.], v. 170, p. 321-335, 2015.

ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ALIMENTOS. **ABIA Relatório Anual 2019.** A indústria brasileira de alimentos e bebidas. São Paulo, 2019.

Disponível em:

<<https://www.abia.org.br/vsn/temp/z202055RelatorioAnual2019.pdf>>. Acesso em: 9 maio. 2020.

ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS DE BISCOITOS, MASSAS ALIMENTÍCIAS E PÃES & BOLOS INDUSTRIALIZADOS. **ABIMAPI Anuário 2020.**

Disponível em:

<[https://www.abimapi.com.br/anuario/anuario.html#your\\_book\\_name/1](https://www.abimapi.com.br/anuario/anuario.html#your_book_name/1)>.

Acesso em: 9 maio. 2020.

BARNEY, J. Firm Resources and Sustained Competitive Advantage. **Journal of Management**, Thousand Oaks, v. 17, n. 1, p. 99-120, 1991.

CECATTO, C.; BELFIORE, P. O uso de métodos de previsão de demanda nas indústrias alimentícias brasileiras. **Gestão & Produção**, São Carlos, v. 22, n. 2, p. 404-418, 2015.

CHASE, C. W. **Demand-driven forecasting: A Structured Approach to Forecasting.**

2th ed. Hoboken: John Wiley & Sons, Inc., v. 1, 2013. 386 p.

- \_\_\_\_\_. **Next Generation Demand Management: People, process, analytics, and technology**. 1th ed. Hoboken: John Wiley & Sons, Inc., 2016. 243 p.
- DE ANGELO, C. F. et al. Séries temporais e redes neurais: uma análise comparativa de técnicas na previsão de vendas do varejo brasileiro. **BBR-Brazilian Business Review**, [S.l.], v. 8, n. 2, p. 1-21, 2011.
- DE GOOIJER, J. G.; FRANCES, P. H. Forecasting and seasonality. **International Journal of Forecasting**, [S.l.], v. 13, n. 3, p. 303–305, 1997.
- DOGANIS, P. et al. Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing. **Journal of Food Engineering**, [S.l.], v. 75, n. 2, p. 196–204, 2006.
- FISHER, M. HAMMOND, J. Making Supply Meet Demand in an Uncertain World. **Harvard Business Review**, Brighton, v. 72, n. 3, p. 83–93, 1994.
- GOODWIN, P.; WRIGHT, G. **Decision Analysis for Management Judgment**. 5th ed. Hoboken: John Wiley & Sons, Inc., 2014. 496 p.
- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman Editora, 2007. 898 p.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. [S.l.], OTexts, 2018. 381 p.
- IVANOV, D.; TSIPOULANIDIS, A.; SCHÖNBERGER, J. **Global Supply Chain and Operations Management**. 2th ed. New York City: Springer, 2019. 606 p.
- LEE, H. L. Aligning supply chain strategies with product uncertainties. **California Management Review**, Berkeley, v. 44, n. 3, p. 105–119, 2002.

- LEE, H. L.; PADMANABHAN, V.; WHANG, S. Information Distortion in a Supply Chain: The Bullwhip Effect. **Management Science**, [S.l.], v. 50, n. 12 Supplement, p. 1875–1886, 2004.
- LEVITT, T. Marketing Myopia Best of HBR 1960. **Harvard Business Review**, Brighton, p. 1–14, 2004.
- MAKRIDAKIS, S. Accuracy measures: theoretical and practical concerns. **International Journal of Forecasting**, [S.l.], v. 9, n. 4, p. 527–529, 1993.
- MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting methods and applications**. 3th ed. Hoboken: John Wiley & Sons, Inc., 2008. 656 p.
- MARINI, F. Non-linear Modeling: Neural Networks. In: **Comprehensive Chemometrics**. 2th ed. Amsterdam: Elsevier, 2020. cap. 3, p. 519–541.
- MELO, D. DE C.; ALCÂNTARA, R. L. C. A gestão da demanda em cadeias de suprimentos: uma abordagem além da previsão de vendas. **Gestão & Produção**, São Carlos, v. 18, n. 4, p. 809–824, 2011.
- MENA, C.; ADENSO-DIAZ, B.; YURT, O. The causes of food waste in the supplier-retailer interface: Evidences from the UK and Spain. **Resources, Conservation and Recycling**, [S.l.], v. 55, n. 6, p. 648–658, 1 abr. 2011.
- MENTZER, J. T.; MOON, M. A. **Sales forecasting management: a demand management approach**. Newbury Park: SAGE Publications Inc., 2005. 347 p.
- MENTZER, J. T; BIENSTOCK, C. C.; KAHN, K. B. Benchmarking sales forecasting management. **Business Horizons**, [S.l.], v. 42, n.3, p. 48–56, 1999.
- MILLER, T. C. **Hierarchical Operations and Supply Chain Planning**. London: Springer-Verlag London, 2002. 262 p.

- NUNES, I.; DA SILVA, H. S. **Artificial neural networks: A Practical Course**. Berlin: Springer Berlin Heidelberg, 2018. 753 p.
- PORTER, M. E. How Competitive Forces Shape Strategy. **Readings in Strategic Management**, [S.l.], p. 133–143, 1989.
- \_\_\_\_\_. **On Competition**. Updated and Expanded Ed. Boston: Harvard Business School Publishing, 2008.
- RENDER, B. **Quantitative analysis for Management**. 13th ed. London: Pearson, 2018. 608 p.
- STADTLER, H. Supply chain management and advanced planning - Basics, overview and challenges. **European Journal of Operational Research**, Amsterdam, v. 163, n. 3, p. 575–588, 2005.
- STADTLER, H.; KILGER, C.; MEYR, H. Springer Texts in Business and Economics: **Supply Chain Management and Advanced Planning**. 5th ed. Berlin: Springer-Verlag Berlin Heidelberg, 2015. 557 p.
- STERMAN, J. D. Modeling managerial behavior: Misperceptions of feedback in a dynamic decision making experiment. **Management science**, [S.l.], v. 35, n. 3, p. 321–339, 1989.
- TAYLOR, D. H; FEARNE, A. Demand management in fresh food value chains: a framework for analysis and improvement. **Supply Chain Management**, [S.l.], v. 14, n. 5, p. 379–392, 2009.
- TSOUMAKAS, G. A survey of machine learning techniques for food sales prediction. **Artificial Intelligence Review**, [S.l.], v. 52, n. 1, p. 441–447, 2019.

UYSAL, M.; EL ROUBI, M. S. Artificial Neural Networks versus Multiple Regression in Tourism Demand Analysis. **Journal of Travel Research**, [S.l.], v. 38, n. 19, p. 111–118, 1999.

ZHANG, G.; PATUWO, E. B.; HU, M. Y. Forecasting with artificial neural networks: The state of the art. **International Journal of Forecasting**, [S.l.], v. 14, p. 35–62, 1998.



## APÊNDICES

Apêndice A - Dados históricos de volume, preço, mídia, renda e share do produto biscoito moldado de chocolate no período de 2013 a 2019.

<b>DADOS HISTÓRICOS</b>					
MÊS	VOLUME	PREÇO	MÍDIA	RENDIA	SHARE
jan/13	464.62	24.91	1	1,589	0.38
fev/13	464.62	24.91	21685	1,609	0.38
mar/13	442.68	24.28	104873	1,611	0.33
abr/13	442.68	24.28	1	1,552	0.33
mai/13	517.29	23.57	100575	1,563	0.32
jun/13	517.29	23.57	184496	1,585	0.32
jul/13	578.11	24.08	42556	1,603	0.33
ago/13	578.11	24.08	63	1,615	0.33
set/13	572.63	24.26	28786	1,618	0.30
out/13	572.63	24.26	115387	1,628	0.30
nov/13	497.15	25.41	360760	1,632	0.28
dez/13	498.15	25.41	1403807	1,643	0.28
jan/14	540.23	23.98	1	1,713	0.41
fev/14	540.23	23.98	8100390	1,739	0.41
mar/14	647.25	24.48	310608	1,758	0.43
abr/14	647.25	24.48	282629	1,709	0.43
mai/14	599.14	25.03	207066	1,720	0.42
jun/14	599.14	25.03	232177	1,722	0.42
jul/14	745.45	25.03	200329	1,723	0.45
ago/14	745.45	25.03	2793962	1,737	0.45
set/14	828.95	24.85	832597	1,744	0.45
out/14	828.95	24.85	6859	1,757	0.45
nov/14	740.51	25.49	124255	1,754	0.42
dez/14	740.51	25.49	555538	1,777	0.42
jan/15	615.93	25.58	4217738	1,857	0.42
fev/15	648.20	25.95	5213730	1,872	0.43
mar/15	715.11	25.53	1	1,878	0.44
abr/15	749.93	25.28	248991	1,829	0.46
mai/15	733.96	25.66	2713	1,837	0.45
jun/15	787.19	25.59	5122	1,860	0.47
jul/15	839.28	25.68	857	1,862	0.49
ago/15	858.56	25.80	42168	1,863	0.49
set/15	818.42	26.42	10965656	1,867	0.47
out/15	879.42	25.97	88669	1,870	0.50
nov/15	825.76	26.20	55189	1,878	0.49
dez/15	820.00	26.86	200466	1,957	0.46
jan/16	832.68	27.05	11073	2,160	0.50
fev/16	887.45	26.54	5171985	2,181	0.52
mar/16	920.78	26.86	6839113	2,158	0.50
abr/16	835.95	27.37	159206	1,973	0.50

MÊS	VOLUME	PREÇO	MIDIA	RENDIA	SHARE
mai/16	902.88	27.76	47987	1,981	0.50
jun/16	897.39	28.45	9805	1,973	0.48
jul/16	920.03	28.73	237397	1,990	0.49
ago/16	1021.56	28.32	338002	2,020	0.49
set/16	998.33	28.87	109051	2,021	0.49
out/16	1012.80	29.07	269770	2,023	0.50
nov/16	964.26	29.77	165693	2,025	0.49
dez/16	1003.62	29.57	651044	2,107	0.51
jan/17	885.54	30.14	1962249	2,308	0.52
fev/17	1026.15	29.68	3835614	2,333	0.52
mar/17	1094.02	29.67	7390790	2,292	0.53
abr/17	1080.39	29.86	57771	2,102	0.54
mai/17	1045.20	29.87	1	2,091	0.55
jun/17	1134.21	29.80	1489	2,081	0.54
jul/17	1122.11	29.36	600684	2,090	0.55
ago/17	1158.14	29.72	7827	2,099	0.53
set/17	1163.56	29.80	374007	2,110	0.51
out/17	1185.95	29.49	525923	2,112	0.51
nov/17	1198.90	29.16	263131	2,117	0.51
dez/17	1133.24	30.34	272339	2,194	0.49
jan/18	1077.92	31.22	2170953	2,404	0.51
fev/18	1142.50	30.01	2179684	2,434	0.50
mar/18	1268.33	29.60	63338	2,374	0.52
abr/18	1163.38	29.56	2547729	2,191	0.53
mai/18	1217.03	29.57	101822	2,188	0.52
jun/18	1215.27	29.48	566875	2,190	0.51
jul/18	993.78	29.79	144344	2,204	0.48
ago/18	993.11	30.01	1	2,232	0.46
set/18	1043.30	31.12	36019	2,232	0.44
out/18	880.40	31.58	130119	2,230	0.41
nov/18	1001.11	31.74	538656	2,230	0.44
dez/18	934.70	32.91	7132	2,323	0.45
jan/19	899.56	33.53	5979	2,553	0.46
fev/19	1024.49	32.12	278	2,574	0.46
mar/19	1024.33	32.64	16281	2,502	0.45
abr/19	1062.27	32.28	1347	2,290	0.46
mai/19	960.56	33.19	3972	2,277	0.44
jun/19	1108.24	31.95	902063	2,288	0.45
jul/19	1169.78	31.67	1	2,295	0.47
ago/19	1177.93	31.57	43894	2,317	0.47
set/19	1178.71	31.46	17986	2,309	0.45
out/19	1144.68	31.36	7351	2,309	0.45
nov/19	1101.52	31.13	6560	2,309	0.43
dez/19	1036.77	31.53	7908	2,309	0.43

## Apêndice B - Avaliação dos dados utilizando o software livre "Gretl"

```

Fatores de Inflacionamento da Variância (VIF)
Valor mínimo possível = 1,0
Valores > 10,0 podem indicar um problema de colinearidade

      PRECO      1,460
      MIDIA      1,072
      RENDA      1,174
      SHARE      1,663

VIF(j) = 1/(1 - R(j)^2), onde R(j) é o coeficiente de correlação múltipla
entre a variável j e a outra variável independente

Diagnósticos de colinearidade de Belsley-Kuh-Welsch:

proporções de variância

lambda   cond   const   PRECO   MIDIA   RENDA   SHARE
4,190    1,000   0,000   0,000   0,011   0,000   0,001
0,790    2,303   0,000   0,000   0,921   0,000   0,000
0,014    17,327   0,003   0,007   0,009   0,005   0,509
0,005    28,353   0,003   0,993   0,057   0,003   0,355
0,000    172,419   0,994   0,000   0,001   0,992   0,135

lambda = eigenvalues of inverse covariance matrix (smallest is 0,000140956)
cond    = índice de condição
nota: as colunas de proporção da variância somam 1

According to BKW, cond >= 30 indicates "strong" near linear dependence,
and cond between 10 and 30 "moderately strong". Parameter estimates whose
variance is mostly associated with problematic cond values may themselves
be considered problematic.

Count of condition indices >= 30: 1
Variance proportions >= 0.5 associated with cond >= 30:

      const      RENDA
      0,994      0,992

Count of condition indices >= 10: 3
Variance proportions >= 0.5 associated with cond >= 10:

      const      PRECO      RENDA      SHARE
      1,000      0,999      1,000      0,999

```

## Apêndice C - Análise de Variância ANOVA

Modelo 1: MQO, usando as observações 1-84				
Variável dependente: VOLUME				
	coeficiente	erro padrão	razão-t	p-valor
const	-2316,41	590,048	-3,926	0,0002 ***
PRECO	44,5217	4,08069	10,91	1,97e-017 ***
MIDIA	-5,55150e-06	4,95856e-06	-1,120	0,2663
RENDA	0,957553	0,483605	1,980	0,0512 *
SHARE	1872,96	192,813	9,714	3,96e-015 ***
Média var. dependente	879,5903	D.P. var. dependente	229,5587	
Soma resid. quadrados	615321,5	E.P. da regressão	88,25463	
R-quadrado	0,859319	R-quadrado ajustado	0,852196	
F(4, 79)	120,6382	P-valor(F)	7,92e-33	
Log da verossimilhança	-492,9523	Critério de Akaike	995,9047	
Critério de Schwarz	1008,059	Critério Hannan-Quinn	1000,791	
Excluindo a constante, a variável com maior p-valor foi 3 (MIDIA)				
Teste de White para a heteroscedasticidade -				
Hipótese nula: sem heteroscedasticidade				
Estatística de teste: LM = 20,9396				
com p-valor = P(Qui-quadrado(14) > 20,9396) = 0,10319				
Teste de White para a heteroscedasticidade (apenas quadrados) -				
Hipótese nula: sem heteroscedasticidade				
Estatística de teste: LM = 17,8131				
com p-valor = P(Qui-quadrado(8) > 17,8131) = 0,0226724				
Teste de Breusch-Pagan para a heteroscedasticidade -				
Hipótese nula: sem heteroscedasticidade				
Estatística de teste: LM = 9,32158				
com p-valor = P(Qui-quadrado(4) > 9,32158) = 0,0535454				
Teste de Breusch-Pagan para a heteroscedasticidade (variante robusta) -				
Hipótese nula: sem heteroscedasticidade				
Estatística de teste: LM = 9,90582				
com p-valor = P(Qui-quadrado(4) > 9,90582) = 0,0420443				

# Apêndice D - Análise de Variância ANOVA

Análise de Variância:			
	Soma dos quadrados	gl	Quadrado da média
Regressão	3,75855e+006	4	939636
Resíduo	615321	79	7788,88
Total	4,37387e+006	83	52697,2
R <sup>2</sup> = 3,75855e+006 / 4,37387e+006 = 0,859319			
F(4, 79) = 939636 / 7788,88 = 120,638 [p-valor 7,92e-033]			

Apêndice E - Média móvel anual centrada de 12 meses foi calculada a partir de série básica original, média móvel de 2 meses, média móvel final, índice sazonal aditivo, índice sazonal multiplicativo

Mês	Volume Base Original	Totais móveis 12 períodos	Totais móveis 2 centrados	Médias móveis centradas	Índice sazonal aditivo	Índice sazonal multiplicati vo
	A	B	C	D = C/24	E= A - D	F = A /D
jan/13	464.62					
fev/13	464.62					
mar/13	442.68					
abr/13	442.68					
mai/13	517.29					
jun/13	517.29					
jul/13	578.11	6145.96	12367.54	515.31	62.79	1.12
ago/13	578.11	6221.58	12518.76	521.62	56.49	1.11
set/13	572.63	6297.19	12798.94	533.29	39.34	1.07
out/13	572.63	6501.76	13208.08	550.34	22.30	1.04
nov/13	497.15	6706.32	13494.50	562.27	-65.12	0.88
dez/13	498.15	6788.17	13658.19	569.09	-70.94	0.88
jan/14	540.23	6870.02	13907.38	579.47	-39.24	0.93
fev/14	540.23	7037.36	14242.06	593.42	-53.19	0.91
mar/14	647.25	7204.70	14665.71	611.07	36.18	1.06
abr/14	647.25	7461.01	15178.35	632.43	14.82	1.02
mai/14	599.14	7717.33	15678.02	653.25	-54.11	0.92
jun/14	599.14	7960.69	16163.74	673.49	-74.35	0.89
jul/14	745.45	8203.05	16481.80	686.74	58.70	1.09
ago/14	745.45	8278.75	16665.47	694.39	51.05	1.07
set/14	828.95	8386.72	16841.30	701.72	127.23	1.18
out/14	828.95	8454.58	17011.83	708.83	120.12	1.17
nov/14	740.51	8557.26	17249.34	718.72	21.79	1.03
dez/14	740.51	8692.08	17572.21	732.18	8.34	1.01
jan/15	615.93	8880.13	17854.10	743.92	-127.99	0.83
fev/15	648.20	8973.97	18061.05	752.54	-104.34	0.86
mar/15	715.11	9087.08	18163.63	756.82	-41.71	0.94
abr/15	749.93	9076.55	18203.57	758.48	-8.55	0.99
mai/15	733.96	9127.02	18339.29	764.14	-30.18	0.96

Mês	Volume Base Original	Totais móveis 12 períodos	Totais móveis 2 centrados	Médias moveis centradas	Índice sazonal aditivo	Índice sazonal multiplicati vo
	A	B	C	D = C/24	E= A - D	F = A /D
jun/15	787.19	9212.27	18504.03	771.00	16.19	1.02
jul/15	839.28	9291.76	18800.27	783.34	55.94	1.07
ago/15	858.56	9508.51	19256.27	802.34	56.22	1.07
set/15	818.42	9747.76	19701.19	820.88	-2.46	1.00
out/15	879.42	9953.43	19992.88	833.04	46.38	1.06
nov/15	825.76	10039.45	20247.82	843.66	-17.90	0.98
dez/15	820.00	10208.37	20526.94	855.29	-35.29	0.96
jan/16	832.68	10318.57	20717.89	863.25	-30.57	0.96
fev/16	887.45	10399.32	20961.64	873.40	14.05	1.02
mar/16	920.78	10562.32	21304.55	887.69	33.09	1.04
abr/16	835.95	10742.23	21617.84	900.74	-64.79	0.93
mai/16	902.88	10875.61	21889.72	912.07	-9.19	0.99
jun/16	897.39	11014.11	22211.84	925.49	-28.10	0.97
jul/16	920.03	11197.73	22448.32	935.35	-15.32	0.98
ago/16	1021.56	11250.59	22639.88	943.33	78.23	1.08
set/16	998.33	11389.29	22951.82	956.33	42.00	1.04
out/16	1012.80	11562.53	23369.50	973.73	39.07	1.04
nov/16	964.26	11806.97	23756.26	989.84	-25.58	0.97
dez/16	1003.62	11949.29	24135.40	1005.64	-2.02	1.00
jan/17	885.54	12186.11	24574.30	1023.93	-138.39	0.86
fev/17	1026.15	12388.19	24912.96	1038.04	-11.89	0.99
mar/17	1094.02	12524.77	25214.77	1050.62	43.40	1.04
abr/17	1080.39	12690.00	25553.15	1064.71	15.68	1.01
mai/17	1045.20	12863.15	25960.94	1081.71	-36.51	0.97
jun/17	1134.21	13097.79	26325.20	1096.88	37.33	1.03
jul/17	1122.11	13227.41	26647.20	1110.30	11.81	1.01
ago/17	1158.14	13419.79	26955.93	1123.16	34.98	1.03
set/17	1163.56	13536.14	27246.59	1135.27	28.29	1.02
out/17	1185.95	13710.45	27503.89	1146.00	39.95	1.03
nov/17	1198.90	13793.44	27758.71	1156.61	42.29	1.04
dez/17	1133.24	13965.27	28011.60	1167.15	-33.91	0.97
jan/18	1077.92	14046.33	27964.33	1165.18	-87.26	0.93



Mês	Volume Base Original	Totais móveis 12 períodos	Totais móveis 2 centrados	Médias móveis centradas	Índice sazonal aditivo	Índice sazonal multiplicati vo
	A	B	C	D = C/24	E= A - D	F = A /D
fev/18	1142.50	13918.00	27670.97	1152.96	-10.46	0.99
mar/18	1268.33	13752.97	27385.68	1141.07	127.26	1.11
abr/18	1163.38	13632.71	26959.87	1123.33	40.05	1.04
mai/18	1217.03	13327.16	26456.53	1102.36	114.67	1.10
jun/18	1215.27	13129.37	26060.21	1085.84	129.43	1.12
jul/18	993.78	12930.83	25683.31	1070.14	-76.36	0.93
ago/18	993.11	12752.47	25386.93	1057.79	-64.68	0.94
set/18	1043.30	12634.46	25024.91	1042.70	0.60	1.00
out/18	880.40	12390.46	24679.80	1028.33	-147.93	0.86
nov/18	1001.11	12289.35	24322.22	1013.43	-12.31	0.99
dez/18	934.70	12032.87	23958.72	998.28	-63.58	0.94
jan/19	899.56	11925.85	24027.70	1001.15	-101.60	0.90
fev/19	1024.49	12101.85	24388.52	1016.19	8.30	1.01
mar/19	1024.33	12286.67	24708.75	1029.53	-5.20	0.99
abr/19	1062.27	12422.08	25108.43	1046.18	16.09	1.02
mai/19	960.56	12686.36	25473.12	1061.38	-100.82	0.91
jun/19	1108.24	12786.76	25675.60	1069.82	38.43	1.04
jul/19	1169.78	12888.84				
ago/19	1177.93					
set/19	1178.71					
out/19	1144.68					
nov/19	1101.52					
dez/19	1036.77					



Apêndice G - Cálculo do ciclo e irregularidades da tendência polinomial,  
para a decomposição aditiva e multiplicativa

Período	Volume Base Original	Tendência Polinomial	Índice Sazonal Aditivo Corrigido	Ciclo Irregular Aditivo	Índice Sazonal Multiplicativo Corrigido	Ciclo Irregular Multiplicativo
	A	B	C	D = A - B - C	E	F = A / B X E
jan/13	464.62	454.55	-86.63	96.70	0.90	1.13
fev/13	464.62	464.26	-25.38	25.74	0.97	1.03
mar/13	442.68	474.26	33.05	-64.62	1.03	0.91
abr/13	442.68	484.51	3.09	-44.92	1.01	0.91
mai/13	517.29	495.02	-18.48	40.75	0.96	1.09
jun/13	517.29	505.77	20.69	-9.18	1.01	1.01
jul/13	578.11	516.74	17.14	44.23	1.03	1.08
ago/13	578.11	527.93	36.26	13.92	1.06	1.03
set/13	572.63	539.32	40.04	-6.73	1.03	1.03
out/13	572.63	550.90	20.86	0.88	1.04	1.00
nov/13	497.15	562.65	-8.60	-56.90	0.99	0.89
dez/13	498.15	574.57	-32.03	-44.39	0.96	0.90
jan/14	540.23	586.63	-86.63	40.23	0.90	1.02
fev/14	540.23	598.84	-25.38	-33.22	0.97	0.93
mar/14	647.25	611.17	33.05	3.04	1.03	1.03
abr/14	647.25	623.61	3.09	20.55	1.01	1.03
mai/14	599.14	636.15	-18.48	-18.53	0.96	0.99
jun/14	599.14	648.78	20.69	-70.34	1.01	0.91
jul/14	745.45	661.49	17.14	66.82	1.03	1.09
ago/14	745.45	674.25	36.26	34.94	1.06	1.04
set/14	828.95	687.07	40.04	101.84	1.03	1.17
out/14	828.95	699.93	20.86	108.16	1.04	1.14
nov/14	740.51	712.81	-8.60	36.30	0.99	1.05
dez/14	740.51	725.70	-32.03	46.84	0.96	1.06
jan/15	615.93	738.59	-86.63	-36.02	0.90	0.92
fev/15	648.20	751.47	-25.38	-77.88	0.97	0.89
mar/15	715.11	764.32	33.05	-82.25	1.03	0.91
abr/15	749.93	777.13	3.09	-30.29	1.01	0.96
mai/15	733.96	789.89	-18.48	-37.45	0.96	0.97
jun/15	787.19	802.59	20.69	-36.09	1.01	0.97
jul/15	839.28	815.21	17.14	6.93	1.03	1.00
ago/15	858.56	827.75	36.26	-5.44	1.06	0.98

<b>Periodo</b>	<b>Volume Base Original</b>	<b>Tendencia Polinomial</b>	<b>Indice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Indice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>
<b>set/15</b>	818.42	840.18	40.04	-61.80	1.03	0.94
<b>out/15</b>	879.42	852.50	20.86	6.06	1.04	0.99
<b>nov/15</b>	825.76	864.69	-8.60	-30.33	0.99	0.96
<b>dez/15</b>	820.00	876.74	-32.03	-24.72	0.96	0.97
<b>jan/16</b>	832.68	888.64	-86.63	30.67	0.90	1.04
<b>fev/16</b>	887.45	900.38	-25.38	12.45	0.97	1.01
<b>mar/16</b>	920.78	911.94	33.05	-24.20	1.03	0.98
<b>abr/16</b>	835.95	923.31	3.09	-90.45	1.01	0.90
<b>mai/16</b>	902.88	934.48	-18.48	-13.11	0.96	1.01
<b>jun/16</b>	897.39	945.43	20.69	-68.73	1.01	0.94
<b>jul/16</b>	920.03	956.15	17.14	-53.26	1.03	0.93
<b>ago/16</b>	1,021.56	966.64	36.26	18.67	1.06	1.00
<b>set/16</b>	998.33	976.87	40.04	-18.58	1.03	0.99
<b>out/16</b>	1,012.80	986.84	20.86	5.10	1.04	0.99
<b>nov/16</b>	964.26	996.53	-8.60	-23.67	0.99	0.98
<b>dez/16</b>	1,003.62	1005.93	-32.03	29.72	0.96	1.04
<b>jan/17</b>	885.54	1015.02	-86.63	-42.85	0.90	0.97
<b>fev/17</b>	1,026.15	1023.81	-25.38	27.73	0.97	1.03
<b>mar/17</b>	1,094.02	1032.26	33.05	28.72	1.03	1.03
<b>abr/17</b>	1,080.39	1040.37	3.09	36.93	1.01	1.03
<b>mai/17</b>	1,045.20	1048.13	-18.48	15.55	0.96	1.04
<b>jun/17</b>	1,134.21	1055.52	20.69	58.00	1.01	1.06
<b>jul/17</b>	1,122.11	1062.53	17.14	42.44	1.03	1.02
<b>ago/17</b>	1,158.14	1069.16	36.26	52.73	1.06	1.02
<b>set/17</b>	1,163.56	1075.37	40.04	48.14	1.03	1.05
<b>out/17</b>	1,185.95	1081.18	20.86	83.91	1.04	1.06
<b>nov/17</b>	1,198.90	1086.55	-8.60	120.95	0.99	1.11
<b>dez/17</b>	1,133.24	1091.48	-32.03	73.78	0.96	1.08
<b>jan/18</b>	1,077.92	1095.96	-86.63	68.59	0.90	1.09
<b>fev/18</b>	1,142.50	1099.97	-25.38	67.91	0.97	1.07
<b>mar/18</b>	1,268.33	1103.50	33.05	131.78	1.03	1.12
<b>abr/18</b>	1,163.38	1106.54	3.09	53.75	1.01	1.04
<b>mai/18</b>	1,217.03	1109.08	-18.48	126.44	0.96	1.15
<b>jun/18</b>	1,215.27	1111.09	20.69	83.48	1.01	1.08
<b>jul/18</b>	993.78	1112.58	17.14	-135.94	1.03	0.86
<b>ago/18</b>	993.11	1113.53	36.26	-156.67	1.06	0.84

<b>Periodo</b>	<b>Volume Base Original</b>	<b>Tendencia Polinomial</b>	<b>Indice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Indice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>
<b>set/18</b>	1,043.30	1113.92	40.04	-110.66	1.03	0.91
<b>out/18</b>	880.40	1113.74	20.86	-254.20	1.04	0.76
<b>nov/18</b>	1,001.11	1112.98	-8.60	-103.27	0.99	0.91
<b>dez/18</b>	934.70	1111.63	-32.03	-144.90	0.96	0.87
<b>jan/19</b>	899.56	1109.68	-86.63	-123.49	0.90	0.90
<b>fev/19</b>	1,024.49	1107.10	-25.38	-57.24	0.97	0.95
<b>mar/19</b>	1,024.33	1103.90	33.05	-112.61	1.03	0.90
<b>abr/19</b>	1,062.27	1100.05	3.09	-40.87	1.01	0.96
<b>mai/19</b>	960.56	1095.55	-18.48	-116.51	0.96	0.92
<b>jun/19</b>	1,108.24	1090.38	20.69	-2.83	1.01	1.00
<b>jul/19</b>	1,169.78	1084.52	17.14	68.12	1.03	1.04
<b>ago/19</b>	1,177.93	1077.98	36.26	63.70	1.06	1.03
<b>set/19</b>	1,178.71	1070.72	40.04	67.94	1.03	1.07
<b>out/19</b>	1,144.68	1062.75	20.86	61.07	1.04	1.04
<b>nov/19</b>	1,101.52	1054.05	-8.60	56.07	0.99	1.06
<b>dez/19</b>	1,036.77	1044.60	-32.03	24.20	0.96	1.03

Apêndice H - Cálculo do ciclo e irregularidades da tendência linear, para a decomposição aditiva e multiplicativa

Período	Volume Base Original	Tendência Linear	Índice Sazonal Aditivo Corrigido	Ciclo Irregular Aditivo	Índice Sazonal Multiplicativo Corrigido	Ciclo Irregular Multiplicativo
	A	B	C	$D = A - B - C$	E	$F = A / B \times E$
jan/13	464.62	522.78	-86.63	28.47	0.90	0.80
fev/13	464.62	539.57	-25.38	-49.57	0.97	0.89
mar/13	442.68	547.97	33.05	-138.33	1.03	0.78
abr/13	442.68	556.36	3.09	-116.77	1.01	0.79
mai/13	517.29	564.76	-18.48	-28.99	0.96	0.96
jun/13	517.29	573.15	20.69	-76.56	1.01	0.89
jul/13	578.11	581.55	17.14	-20.58	1.03	0.96
ago/13	578.11	589.94	36.26	-48.09	1.06	0.92
set/13	572.63	598.34	40.04	-65.75	1.03	0.93
out/13	572.63	606.74	20.86	-54.96	1.04	0.91
nov/13	497.15	615.13	-8.60	-109.38	0.99	0.82
dez/13	498.15	623.53	-32.03	-93.35	0.96	0.83
jan/14	540.23	631.92	-86.63	-5.06	0.90	0.95
fev/14	540.23	640.32	-25.38	-74.71	0.97	0.87
mar/14	647.25	648.71	33.05	-34.51	1.03	0.97
abr/14	647.25	657.11	3.09	-12.95	1.01	0.98
mai/14	599.14	665.51	-18.48	-47.89	0.96	0.94
jun/14	599.14	673.90	20.69	-95.46	1.01	0.88
jul/14	745.45	682.30	17.14	46.01	1.03	1.06
ago/14	745.45	690.69	36.26	18.50	1.06	1.02
set/14	828.95	699.09	40.04	89.82	1.03	1.15
out/14	828.95	707.48	20.86	100.61	1.04	1.13
nov/14	740.51	715.88	-8.60	33.23	0.99	1.05
dez/14	740.51	724.27	-32.03	48.26	0.96	1.06
jan/15	615.93	732.67	-86.63	-30.11	0.90	0.93
fev/15	648.20	741.07	-25.38	-67.48	0.97	0.90
mar/15	715.11	749.46	33.05	-67.40	1.03	0.93
abr/15	749.93	757.86	3.09	-11.02	1.01	0.98
mai/15	733.96	766.25	-18.48	-13.81	0.96	1.00
jun/15	787.19	774.65	20.69	-8.15	1.01	1.00
jul/15	839.28	783.04	17.14	39.10	1.03	1.04

<b>Periodo</b>	<b>Volume Base Original</b>	<b>Tendencia Linear</b>	<b>Indice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Indice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>
<b>ago/15</b>	858.56	791.44	36.26	30.86	1.06	1.02
<b>set/15</b>	818.42	799.83	40.04	-21.46	1.03	0.99
<b>out/15</b>	879.42	808.23	20.86	50.33	1.04	1.05
<b>nov/15</b>	825.76	816.63	-8.60	17.73	0.99	1.02
<b>dez/15</b>	820.00	825.02	-32.03	27.00	0.96	1.03
<b>jan/16</b>	832.68	833.42	-86.63	85.90	0.90	1.11
<b>fev/16</b>	887.45	841.81	-25.38	71.02	0.97	1.09
<b>mar/16</b>	920.78	850.21	33.05	37.53	1.03	1.05
<b>abr/16</b>	835.95	858.60	3.09	-25.74	1.01	0.97
<b>mai/16</b>	902.88	867.00	-18.48	54.36	0.96	1.09
<b>jun/16</b>	897.39	875.40	20.69	1.30	1.01	1.01
<b>jul/16</b>	920.03	883.79	17.14	19.10	1.03	1.01
<b>ago/16</b>	1,021.56	892.19	36.26	93.12	1.06	1.08
<b>set/16</b>	998.33	900.58	40.04	57.71	1.03	1.07
<b>out/16</b>	1,012.80	908.98	20.86	82.96	1.04	1.07
<b>nov/16</b>	964.26	917.37	-8.60	55.49	0.99	1.06
<b>dez/16</b>	1,003.62	925.77	-32.03	109.88	0.96	1.13
<b>jan/17</b>	885.54	934.16	-86.63	38.01	0.90	1.05
<b>fev/17</b>	1,026.15	942.56	-25.38	108.97	0.97	1.12
<b>mar/17</b>	1,094.02	950.96	33.05	110.02	1.03	1.12
<b>abr/17</b>	1,080.39	959.35	3.09	117.95	1.01	1.12
<b>mai/17</b>	1,045.20	967.75	-18.48	95.93	0.96	1.13
<b>jun/17</b>	1,134.21	976.14	20.69	137.37	1.01	1.15
<b>jul/17</b>	1,122.11	984.54	17.14	120.44	1.03	1.10
<b>ago/17</b>	1,158.14	992.93	36.26	128.95	1.06	1.10
<b>set/17</b>	1,163.56	1001.33	40.04	122.19	1.03	1.13
<b>out/17</b>	1,185.95	1009.72	20.86	155.37	1.04	1.13
<b>nov/17</b>	1,198.90	1018.12	-8.60	189.38	0.99	1.19
<b>dez/17</b>	1,133.24	1026.52	-32.03	138.75	0.96	1.15
<b>jan/18</b>	1,077.92	1034.91	-86.63	129.64	0.90	1.15
<b>fev/18</b>	1,142.50	1043.31	-25.38	124.57	0.97	1.13
<b>mar/18</b>	1,268.33	1051.70	33.05	183.58	1.03	1.17
<b>abr/18</b>	1,163.38	1060.10	3.09	100.19	1.01	1.09
<b>mai/18</b>	1,217.03	1068.49	-18.48	167.02	0.96	1.19
<b>jun/18</b>	1,215.27	1076.89	20.69	117.69	1.01	1.12

<b>Periodo</b>	<b>Volume Base Original</b>	<b>Tendencia Linear</b>	<b>Indice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Indice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>
<b>jul/18</b>	993.78	1085.29	17.14	-108.64	1.03	0.89
<b>ago/18</b>	993.11	1093.68	36.26	-136.83	1.06	0.86
<b>set/18</b>	1,043.30	1102.08	40.04	-98.82	1.03	0.92
<b>out/18</b>	880.40	1110.47	20.86	-250.93	1.04	0.76
<b>nov/18</b>	1,001.11	1118.87	-8.60	-109.15	0.99	0.90
<b>dez/18</b>	934.70	1127.26	-32.03	-160.54	0.96	0.86
<b>jan/19</b>	899.56	1135.66	-86.63	-149.47	0.90	0.88
<b>fev/19</b>	1,024.49	1144.05	-25.38	-94.19	0.97	0.92
<b>mar/19</b>	1,024.33	1152.45	33.05	-161.17	1.03	0.86
<b>abr/19</b>	1,062.27	1160.85	3.09	-101.66	1.01	0.91
<b>mai/19</b>	960.56	1169.24	-18.48	-190.20	0.96	0.86
<b>jun/19</b>	1,108.24	1177.64	20.69	-90.09	1.01	0.93
<b>jul/19</b>	1,169.78	1186.03	17.14	-33.39	1.03	0.95
<b>ago/19</b>	1,177.93	1194.43	36.26	-52.75	1.06	0.93
<b>set/19</b>	1,178.71	1202.82	40.04	-64.16	1.03	0.95
<b>out/19</b>	1,144.68	1211.22	20.86	-87.40	1.04	0.91
<b>nov/19</b>	1,101.52	1219.61	-8.60	-109.50	0.99	0.91
<b>dez/19</b>	1,036.77	1228.01	-32.03	-159.21	0.96	0.88



Apêndice I - Cálculo da mediana dos ciclos de alta e dos ciclos de baixa separadamente, para a tendência polinomial aditiva e multiplicativa

<b>Correção para a Tendência Polinomial</b>	
<b>Ciclo Irregular Aditivo</b>	
Recomposição	
Período de Alta	44,227
Período de Baixa	- 44,654
<b>Ciclo Irregular Multiplicativo</b>	
Recomposição	
Período de Alta	1,043
Período de Baixa	0,930

<b>Correção para a Tendência Linear</b>	
<b>Ciclo Irregular Aditivo</b>	
Recomposição	
Período de Alta	89,822
Período de Baixa	- 74,707
<b>Ciclo Irregular Multiplicativo</b>	
Recomposição	
Período de Alta	1,089
Período de Baixa	0,909

Apêndice J - Recomposição da tendência polinomial, aditiva e multiplicativa

<b>Periodo</b>	<b>Tendencia Polinomial</b>	<b>Indice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Y Polinomial aditivo</b>	<b>Indice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>	<b>Y Polinomial Multiplicativo</b>
<b>jan/13</b>	454.55	-86.63	44.23	412.14	0.90	1.04	427.64
<b>fev/13</b>	464.26	-25.38	44.23	483.11	0.97	1.04	470.23
<b>mar/13</b>	474.26	33.05	-44.65	462.65	1.03	0.93	454.32
<b>abr/13</b>	484.51	3.09	-44.65	442.95	1.01	0.93	453.98
<b>mai/13</b>	495.02	-18.48	44.23	520.77	0.96	1.04	493.13
<b>jun/13</b>	505.77	20.69	-44.65	481.81	1.01	1.04	533.63
<b>jul/13</b>	516.74	17.14	44.23	578.11	1.03	1.04	557.37
<b>ago/13</b>	527.93	36.26	44.23	608.42	1.06	1.04	584.05
<b>set/13</b>	539.32	40.04	-44.65	534.71	1.03	1.04	580.60
<b>out/13</b>	550.90	20.86	44.23	615.98	1.04	1.04	597.07
<b>nov/13</b>	562.65	-8.60	-44.65	509.40	0.99	0.93	517.91
<b>dez/13</b>	574.57	-32.03	-44.65	497.88	0.96	0.93	514.61
<b>jan/14</b>	586.63	-86.63	44.23	544.23	0.90	1.04	551.90
<b>fev/14</b>	598.84	-25.38	-44.65	528.80	0.97	0.93	541.07
<b>mar/14</b>	611.17	33.05	44.23	688.44	1.03	1.04	656.29
<b>abr/14</b>	623.61	3.09	44.23	670.92	1.01	1.04	654.99
<b>mai/14</b>	636.15	-18.48	-44.65	573.01	0.96	0.93	565.33
<b>jun/14</b>	648.78	20.69	-44.65	624.82	1.01	0.93	610.65
<b>jul/14</b>	661.49	17.14	44.23	722.85	1.03	1.04	713.49
<b>ago/14</b>	674.25	36.26	44.23	754.74	1.06	1.04	745.92
<b>set/14</b>	687.07	40.04	44.23	771.34	1.03	1.04	739.66
<b>out/14</b>	699.93	20.86	44.23	765.01	1.04	1.04	758.60
<b>nov/14</b>	712.81	-8.60	44.23	748.43	0.99	1.04	735.50
<b>dez/14</b>	725.70	-32.03	44.23	737.90	0.96	1.04	728.60
<b>jan/15</b>	738.59	-86.63	-44.65	607.30	0.90	0.93	619.88
<b>fev/15</b>	751.47	-25.38	-44.65	681.43	0.97	0.93	678.98
<b>mar/15</b>	764.32	33.05	-44.65	752.71	1.03	0.93	732.18
<b>abr/15</b>	777.13	3.09	-44.65	735.57	1.01	0.93	728.15
<b>mai/15</b>	789.89	-18.48	-44.65	726.76	0.96	0.93	701.95
<b>jun/15</b>	802.59	20.69	-44.65	778.63	1.01	0.93	755.42
<b>jul/15</b>	815.21	17.14	44.23	876.58	1.03	0.93	784.41
<b>ago/15</b>	827.75	36.26	-44.65	819.35	1.06	0.93	816.91

<b>Periodo</b>	<b>Tendencia Polinomial</b>	<b>Indice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Y Polinomial aditivo</b>	<b>Indice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>	<b>Y Polinomial Multiplicativo</b>
<b>set/15</b>	840.18	40.04	-44.65	835.57	1.03	0.93	806.89
<b>out/15</b>	852.50	20.86	44.23	917.58	1.04	0.93	824.25
<b>nov/15</b>	864.69	-8.60	-44.65	811.44	0.99	0.93	795.93
<b>dez/15</b>	876.74	-32.03	-44.65	800.06	0.96	0.93	785.26
<b>jan/16</b>	888.64	-86.63	44.23	846.24	0.90	1.04	836.03
<b>fev/16</b>	900.38	-25.38	44.23	919.23	0.97	1.04	911.94
<b>mar/16</b>	911.94	33.05	-44.65	900.33	1.03	0.93	873.59
<b>abr/16</b>	923.31	3.09	-44.65	881.74	1.01	0.93	865.12
<b>mai/16</b>	934.48	-18.48	-44.65	871.34	0.96	1.04	930.90
<b>jun/16</b>	945.43	20.69	-44.65	921.47	1.01	0.93	889.86
<b>jul/16</b>	956.15	17.14	-44.65	928.64	1.03	0.93	920.03
<b>ago/16</b>	966.64	36.26	44.23	1047.12	1.06	0.93	953.98
<b>set/16</b>	976.87	40.04	-44.65	972.26	1.03	0.93	938.16
<b>out/16</b>	986.84	20.86	44.23	1051.92	1.04	0.93	954.14
<b>nov/16</b>	996.53	-8.60	-44.65	943.28	0.99	0.93	917.29
<b>dez/16</b>	1005.93	-32.03	44.23	1018.13	0.96	1.04	1009.95
<b>jan/17</b>	1015.02	-86.63	-44.65	883.74	0.90	0.93	851.89
<b>fev/17</b>	1023.81	-25.38	44.23	1042.65	0.97	1.04	1036.95
<b>mar/17</b>	1032.26	33.05	44.23	1109.53	1.03	1.04	1108.47
<b>abr/17</b>	1040.37	3.09	44.23	1087.69	1.01	1.04	1092.72
<b>mai/17</b>	1048.13	-18.48	44.23	1073.87	0.96	1.04	1044.11
<b>jun/17</b>	1055.52	20.69	44.23	1120.44	1.01	1.04	1113.66
<b>jul/17</b>	1062.53	17.14	44.23	1123.90	1.03	1.04	1146.07
<b>ago/17</b>	1069.16	36.26	44.23	1149.64	1.06	1.04	1182.80
<b>set/17</b>	1075.37	40.04	44.23	1159.64	1.03	1.04	1157.69
<b>out/17</b>	1081.18	20.86	44.23	1146.26	1.04	1.04	1171.80
<b>nov/17</b>	1086.55	-8.60	44.23	1122.18	0.99	1.04	1121.14
<b>dez/17</b>	1091.48	-32.03	44.23	1103.68	0.96	1.04	1095.85
<b>jan/18</b>	1095.96	-86.63	44.23	1053.55	0.90	1.04	1031.08
<b>fev/18</b>	1099.97	-25.38	44.23	1118.82	0.97	1.04	1114.10
<b>mar/18</b>	1103.50	33.05	44.23	1180.77	1.03	1.04	1184.98
<b>abr/18</b>	1106.54	3.09	44.23	1153.86	1.01	1.04	1162.22
<b>mai/18</b>	1109.08	-18.48	44.23	1134.82	0.96	1.04	1104.83
<b>jun/18</b>	1111.09	20.69	44.23	1176.01	1.01	1.04	1172.30
<b>jul/18</b>	1112.58	17.14	-44.65	1085.06	1.03	0.93	1070.55

<b>Periodo</b>	<b>Tendencia Polinomial</b>	<b>Indice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Y Polinomial aditivo</b>	<b>Indice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>	<b>Y Polinomial Multiplicativo</b>
<b>ago/18</b>	1113.53	36.26	-44.65	1105.13	1.06	0.93	1098.95
<b>set/18</b>	1113.92	40.04	-44.65	1109.30	1.03	0.93	1069.78
<b>out/18</b>	1113.74	20.86	-44.65	1089.94	1.04	0.93	1076.83
<b>nov/18</b>	1112.98	-8.60	-44.65	1059.73	0.99	0.93	1024.48
<b>dez/18</b>	1111.63	-32.03	-44.65	1034.95	0.96	0.93	995.64
<b>jan/19</b>	1109.68	-86.63	-44.65	978.39	0.90	0.93	931.32
<b>fev/19</b>	1107.10	-25.38	-44.65	1037.07	0.97	0.93	1000.31
<b>mar/19</b>	1103.90	33.05	-44.65	1092.29	1.03	0.93	1057.48
<b>abr/19</b>	1100.05	3.09	-44.65	1058.49	1.01	0.93	1030.72
<b>mai/19</b>	1095.55	-18.48	-44.65	1032.41	0.96	0.93	973.58
<b>jun/19</b>	1090.38	20.69	-44.65	1066.41	1.01	1.04	1150.44
<b>jul/19</b>	1084.52	17.14	44.23	1145.89	1.03	1.04	1169.78
<b>ago/19</b>	1077.98	36.26	44.23	1158.46	1.06	1.04	1192.55
<b>set/19</b>	1070.72	40.04	44.23	1154.99	1.03	1.04	1152.68
<b>out/19</b>	1062.75	20.86	44.23	1127.84	1.04	1.04	1151.83
<b>nov/19</b>	1054.05	-8.60	44.23	1089.68	0.99	1.04	1087.60
<b>dez/19</b>	1044.60	-32.03	44.23	1056.80	0.96	1.04	1048.78

## Apêndice K - Recomposição da tendência linear, aditiva e multiplicativa

<b>Período</b>	<b>Tendência Linear</b>	<b>Índice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Y Linear aditivo</b>	<b>Índice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>	<b>Y Linear Multiplicativo</b>
jan/13	531.1756	-86.633	87.859	532.401	0.902	0.911	436.584
fev/13	539.5712	-25.381	-74.707	439.483	0.972	0.911	477.444
mar/13	547.9668	33.046	-74.707	506.305	1.030	0.911	514.072
abr/13	556.3624	3.090	-74.707	484.745	1.007	0.911	510.520
mai/13	564.758	-18.482	-74.707	471.569	0.956	0.911	491.505
jun/13	573.1536	20.694	-74.707	519.140	1.012	0.911	528.311
jul/13	581.5492	17.136	-74.707	523.978	1.035	0.911	548.007
ago/13	589.9448	36.256	-74.707	551.494	1.061	0.911	570.181
set/13	598.3404	40.040	-74.707	563.674	1.033	0.911	562.747
out/13	606.736	20.859	-74.707	552.887	1.040	0.911	574.500
nov/13	615.1316	-8.598	-74.707	531.826	0.990	0.911	554.511
dez/13	623.5272	-32.026	-74.707	516.794	0.963	0.911	546.918
jan/14	631.9228	-86.633	-74.707	470.582	0.902	0.911	519.390
fev/14	640.3184	-25.381	-74.707	540.230	0.972	0.911	566.591
mar/14	648.714	33.046	-74.707	607.052	1.030	0.911	608.587
abr/14	657.1096	3.090	-74.707	585.492	1.007	0.911	602.966
mai/14	665.5052	-18.482	-74.707	572.316	0.956	0.911	579.184
jun/14	673.9008	20.694	-74.707	619.887	1.012	0.911	621.176
jul/14	682.2964	17.136	87.859	787.291	1.035	1.089	768.941
ago/14	690.692	36.256	87.859	814.807	1.061	1.089	798.374
set/14	699.0876	40.040	87.859	826.987	1.033	1.089	786.352
out/14	707.4832	20.859	87.859	816.201	1.040	1.089	801.174
nov/14	715.8788	-8.598	87.859	795.139	0.990	1.089	771.795
dez/14	724.2744	-32.026	87.859	780.107	0.963	1.089	759.784
jan/15	732.67	-86.633	-74.707	571.330	0.902	0.911	602.196
fev/15	741.0656	-25.381	-74.707	640.977	0.972	0.911	655.738
mar/15	749.4612	33.046	-74.707	707.799	1.030	0.911	703.103
abr/15	757.8568	3.090	-74.707	686.239	1.007	0.911	695.412
mai/15	766.2524	-18.482	-74.707	673.064	0.956	1.089	797.549
jun/15	774.648	20.694	-74.707	720.634	1.012	1.089	853.972
jul/15	783.0436	17.136	87.859	888.039	1.035	1.089	882.482
ago/15	791.4392	36.256	87.859	915.554	1.061	1.089	914.828

<b>Periodo</b>	<b>Tendencia Linear</b>	<b>Indice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Y Linear aditivo</b>	<b>Indice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>	<b>Y Linear Multiplicativo</b>
set/15	799.8348	40.040	-74.707	765.168	1.033	0.911	752.256
out/15	808.2304	20.859	87.859	916.948	1.040	1.089	915.263
nov/15	816.626	-8.598	87.859	895.886	0.990	1.089	880.412
dez/15	825.0216	-32.026	87.859	880.854	0.963	1.089	865.470
jan/16	833.4172	-86.633	87.859	834.643	0.902	1.089	819.243
fev/16	841.8128	-25.381	87.859	904.291	0.972	1.089	890.861
mar/16	850.2084	33.046	87.859	971.113	1.030	1.089	953.928
abr/16	858.604	3.090	-74.707	786.986	1.007	0.911	787.858
mai/16	866.9996	-18.482	87.859	936.377	0.956	1.089	902.412
jun/16	875.3952	20.694	87.859	983.948	1.012	1.089	965.036
jul/16	883.7908	17.136	87.859	988.786	1.035	1.089	996.023
ago/16	892.1864	36.256	87.859	1016.30	1.061	1.089	1031.282
set/16	900.582	40.040	87.859	1028.48	1.033	1.089	1012.999
out/16	908.9776	20.859	87.859	1017.69	1.040	1.089	1029.352
nov/16	917.3732	-8.598	87.859	996.633	0.990	1.089	989.028
dez/16	925.7688	-32.026	87.859	981.601	0.963	1.089	971.157
jan/17	934.1644	-86.633	87.859	935.390	0.902	1.089	918.276
fev/17	942.56	-25.381	87.859	1005.03	0.972	1.089	997.478
mar/17	950.9556	33.046	87.859	1071.86	1.030	1.089	1066.965
abr/17	959.3512	3.090	87.859	1050.30	1.007	1.089	1052.817
mai/17	967.7468	-18.482	87.859	1037.12	0.956	1.089	1007.274
jun/17	976.1424	20.694	87.859	1084.69	1.012	1.089	1076.100
jul/17	984.538	17.136	87.859	1089.53	1.035	1.089	1109.564
ago/17	992.9336	36.256	87.859	1117.04	1.061	1.089	1147.736
set/17	1001.3292	40.040	87.859	1129.22	1.033	1.089	1126.322
out/17	1009.7248	20.859	87.859	1118.44	1.040	1.089	1143.441
nov/17	1018.1204	-8.598	87.859	1097.38	0.990	1.089	1097.645
dez/17	1026.516	-32.026	87.859	1082.34	0.963	1.089	1076.844
jan/18	1034.9116	-86.633	87.859	1036.13	0.902	1.089	1017.310
fev/18	1043.3072	-25.381	87.859	1105.78	0.972	1.089	1104.095
mar/18	1051.7028	33.046	87.859	1172.60	1.030	1.089	1180.003
abr/18	1060.0984	3.090	87.859	1151.04	1.007	1.089	1163.380
mai/18	1068.494	-18.482	87.859	1137.87	0.956	1.089	1112.136

<b>Periodo</b>	<b>Tendencia Linear</b>	<b>Indice Sazonal Aditivo Corrigido</b>	<b>Ciclo Irregular Aditivo</b>	<b>Y Linear aditivo</b>	<b>Indice Sazonal Multiplicativo Corrigido</b>	<b>Ciclo Irregular Multiplicativo</b>	<b>Y Linear Multiplicativo</b>
jun/18	1076.8896	20.694	87.859	1185.44	1.012	1.089	1187.164
jul/18	1085.2852	17.136	-74.707	1027.71	1.035	0.911	1022.688
ago/18	1093.6808	36.256	-74.707	1055.23	1.061	0.911	1057.042
set/18	1102.0764	40.040	-74.707	1067.41	1.033	0.911	1036.518
out/18	1110.472	20.859	-74.707	1056.62	1.040	0.911	1051.472
nov/18	1118.8676	-8.598	-74.707	1035.56	0.990	0.911	1008.605
dez/18	1127.2632	-32.026	-74.707	1020.53	0.963	0.911	988.762
jan/19	1135.6588	-86.633	-74.707	974.318	0.902	0.911	933.421
fev/19	1144.0544	-25.381	-74.707	1043.96	0.972	0.911	1012.326
mar/19	1152.45	33.046	-74.707	1110.78	1.030	0.911	1081.164
abr/19	1160.8456	3.090	-74.707	1089.22	1.007	0.911	1065.196
mai/19	1169.2412	-18.482	-74.707	1076.05	0.956	0.911	1017.582
jun/19	1177.6368	20.694	-74.707	1123.62	1.012	0.911	1085.501
jul/19	1186.0324	17.136	-74.707	1128.46	1.035	0.911	1117.625
ago/19	1194.428	36.256	-74.707	1155.97	1.061	0.911	1154.414
set/19	1202.8236	40.040	-74.707	1168.15	1.033	0.911	1131.272
out/19	1211.2192	20.859	-74.707	1157.37	1.040	0.911	1146.867
nov/19	1219.6148	-8.598	-74.707	1136.30	0.990	0.911	1099.423
dez/19	1228.0104	-32.026	-74.707	1121.27	0.963	0.911	1077.131

## Apêndice L - Cálculo da acurácia da tendência polinomial corrigida

<b>Período</b>	<b>Y Polinomial aditivo</b>	<b>Y Polinomial Multiplicativ</b>	<b>Erro Aditivo</b>	<b>Modulo do erro aditivo</b>	<b>Erro Quadratico</b>	<b>Erro Percentual (%) Aditivo</b>	<b>Modulo do Erro Percentual (%) Aditivo</b>	<b>Erro Multiplicativ o</b>	<b>Modulo Erro Multiplicativ o</b>	<b>Erro Quadratico Multiplicativ</b>	<b>Erro Percentual (%) Multiplicativ</b>	<b>Modulo do Erro Percentual (%) Multiplicativ</b>
jan/13	412.14	427.64	52.48	52.48	2753.87	11.29	11.29	36.98	36.98	1367.56	7.96	7.96
fev/13	483.11	470.23	-18.49	18.49	341.94	-3.98	3.98	-5.61	5.61	31.44	-1.21	1.21
mar/13	462.65	454.32	-19.97	19.97	398.61	-4.51	4.51	-11.63	11.63	135.34	-2.63	2.63
abr/13	442.95	453.98	-0.27	0.27	0.07	-0.06	0.06	-11.30	11.30	127.62	-2.55	2.55
mai/13	520.77	493.13	-3.48	3.48	12.12	-0.67	0.67	24.16	24.16	583.75	4.67	4.67
jun/13	481.81	533.63	35.48	35.48	1258.65	6.86	6.86	-16.34	16.34	267.08	-3.16	3.16
jul/13	578.11	557.37	0.00	0.00	0.00	0.00	0.00	20.74	20.74	430.10	3.59	3.59
ago/13	608.42	584.05	-30.31	30.31	918.53	-5.24	5.24	-5.94	5.94	35.26	-1.03	1.03
set/13	534.71	580.60	37.93	37.93	1438.43	6.62	6.62	-7.97	7.97	63.52	-1.39	1.39
out/13	615.98	597.07	-43.35	43.35	1879.18	-7.57	7.57	-24.44	24.44	597.36	-4.27	4.27
nov/13	509.40	517.91	-12.25	12.25	149.95	-2.46	2.46	-20.76	20.76	430.98	-4.18	4.18
dez/13	497.88	514.61	0.27	0.27	0.07	0.05	0.05	-16.46	16.46	271.00	-3.30	3.30
jan/14	544.23	551.90	-4.00	4.00	15.96	-0.74	0.74	-11.67	11.67	136.25	-2.16	2.16
fev/14	528.80	541.07	11.43	11.43	130.64	2.12	2.12	-0.84	0.84	0.71	-0.16	0.16
mar/14	688.44	656.29	-41.19	41.19	1696.30	-6.36	6.36	-9.04	9.04	81.69	-1.40	1.40
abr/14	670.92	654.99	-23.67	23.67	560.40	-3.66	3.66	-7.74	7.74	59.87	-1.20	1.20
mai/14	573.01	565.33	26.12	26.12	682.35	4.36	4.36	33.81	33.81	1143.04	5.64	5.64
jun/14	624.82	610.65	-25.68	25.68	659.65	-4.29	4.29	-11.51	11.51	132.55	-1.92	1.92
jul/14	722.85	713.49	22.60	22.60	510.60	3.03	3.03	31.96	31.96	1021.20	4.29	4.29
ago/14	754.74	745.92	-9.29	9.29	86.33	-1.25	1.25	-0.47	0.47	0.23	-0.06	0.06
set/14	771.34	739.66	57.61	57.61	3318.99	6.95	6.95	89.29	89.29	7971.87	10.77	10.77
out/14	765.01	758.60	63.94	63.94	4088.05	7.71	7.71	70.35	70.35	4949.76	8.49	8.49
nov/14	748.43	735.50	-7.92	7.92	62.78	-1.07	1.07	5.01	5.01	25.14	0.68	0.68



<b>Periodo</b>	<b>Y Polinomial aditivo</b>	<b>Y Polinomial Multiplicativ</b>	<b>Erro Aditivo</b>	<b>Modulo do erro aditivo</b>	<b>Erro Quadratico</b>	<b>Erro Percentual (%) Aditivo</b>	<b>Modulo do Erro Percentual (%) Aditivo</b>	<b>Erro Multiplicativ</b>	<b>Modulo Erro Multiplicativ</b>	<b>Erro Quadratico Multiplicativ</b>	<b>Erro Percentual (%) Multiplicativ</b>	<b>Modulo do Erro Percentual (%) Multiplicativ</b>
dez/14	737.90	728.60	2.61	2.61	6.83	0.35	0.35	11.91	11.91	141.86	1.61	1.61
jan/15	607.30	619.88	8.63	8.63	74.48	1.40	1.40	-3.95	3.95	15.59	-0.64	0.64
fev/15	681.43	678.98	-33.23	33.23	1104.21	-5.13	5.13	-30.78	30.78	947.47	-4.75	4.75
mar/15	752.71	732.18	-37.60	37.60	1413.60	-5.26	5.26	-17.07	17.07	291.39	-2.39	2.39
abr/15	735.57	728.15	14.36	14.36	206.35	1.92	1.92	21.78	21.78	474.16	2.90	2.90
mai/15	726.76	701.95	7.20	7.20	51.89	0.98	0.98	32.01	32.01	1024.43	4.36	4.36
jun/15	778.63	755.42	8.56	8.56	73.27	1.09	1.09	31.77	31.77	1009.35	4.04	4.04
jul/15	876.58	784.41	-37.30	37.30	1391.04	-4.44	4.44	54.87	54.87	3010.20	6.54	6.54
ago/15	819.35	816.91	39.21	39.21	1537.50	4.57	4.57	41.65	41.65	1734.72	4.85	4.85
set/15	835.57	806.89	-17.15	17.15	293.97	-2.09	2.09	11.53	11.53	133.03	1.41	1.41
out/15	917.58	824.25	-38.16	38.16	1456.44	-4.34	4.34	55.17	55.17	3043.82	6.27	6.27
nov/15	811.44	795.93	14.32	14.32	205.16	1.73	1.73	29.83	29.83	889.55	3.61	3.61
dez/15	800.06	785.26	19.94	19.94	397.55	2.43	2.43	34.74	34.74	1206.88	4.24	4.24
jan/16	846.24	836.03	-13.56	13.56	183.78	-1.63	1.63	-3.35	3.35	11.26	-0.40	0.40
fev/16	919.23	911.94	-31.78	31.78	1009.65	-3.58	3.58	-24.49	24.49	599.81	-2.76	2.76
mar/16	900.33	873.59	20.45	20.45	418.23	2.22	2.22	47.19	47.19	2226.44	5.12	5.12
abr/16	881.74	865.12	-45.79	45.79	2097.02	-5.48	5.48	-29.17	29.17	850.92	-3.49	3.49
mai/16	871.34	930.90	31.54	31.54	994.80	3.49	3.49	-28.02	28.02	784.85	-3.10	3.10
jun/16	921.47	889.86	-24.08	24.08	579.73	-2.68	2.68	7.53	7.53	56.67	0.84	0.84
jul/16	928.64	920.03	-8.61	8.61	74.05	-0.94	0.94	0.00	0.00	0.00	0.00	0.00
ago/16	1047.12	953.98	-25.56	25.56	653.41	-2.50	2.50	67.58	67.58	4566.62	6.62	6.62
set/16	972.26	938.16	26.07	26.07	679.77	2.61	2.61	60.17	60.17	3620.24	6.03	6.03
out/16	1051.92	954.14	-39.12	39.12	1530.73	-3.86	3.86	58.66	58.66	3441.13	5.79	5.79
nov/16	943.28	917.29	20.98	20.98	440.33	2.18	2.18	46.97	46.97	2206.10	4.87	4.87

Período	Y Polinomial aditivo	Y Polinomial Multiplicativ	Erro Aditivo	Modulo do erro aditivo	Erro Quadratico	Erro Percentual (%) Aditivo	Modulo do Erro Percentual (%) Aditivo	Erro Multiplicativ	Modulo Erro Multiplicativ	Erro Quadratico Multiplicativ	Erro Percentual (%) Multiplicativ	Modulo do Erro Percentual (%) Multiplicativ
dez/16	1018.13	1009.95	-14.51	14.51	210.50	-1.45	1.45	-6.33	6.33	40.10	-0.63	0.63
jan/17	883.74	851.89	1.80	1.80	3.25	0.20	0.20	33.65	33.65	1132.64	3.80	3.80
fev/17	1042.65	1036.95	-16.50	16.50	272.28	-1.61	1.61	-10.80	10.80	116.68	-1.05	1.05
mar/17	1109.53	1108.47	-15.51	15.51	240.56	-1.42	1.42	-14.45	14.45	208.89	-1.32	1.32
abr/17	1087.69	1092.72	-7.30	7.30	53.23	-0.68	0.68	-12.33	12.33	152.10	-1.14	1.14
mai/17	1073.87	1044.11	-28.67	28.67	822.14	-2.74	2.74	1.09	1.09	1.18	0.10	0.10
jun/17	1120.44	1113.66	13.77	13.77	189.60	1.21	1.21	20.55	20.55	422.27	1.81	1.81
jul/17	1123.90	1146.07	-1.79	1.79	3.19	-0.16	0.16	-23.96	23.96	573.88	-2.13	2.13
ago/17	1149.64	1182.80	8.50	8.50	72.26	0.73	0.73	-24.66	24.66	607.95	-2.13	2.13
set/17	1159.64	1157.69	3.92	3.92	15.35	0.34	0.34	5.87	5.87	34.45	0.50	0.50
out/17	1146.26	1171.80	39.69	39.69	1575.09	3.35	3.35	14.15	14.15	200.14	1.19	1.19
nov/17	1122.18	1121.14	76.72	76.72	5886.14	6.40	6.40	77.76	77.76	6046.71	6.49	6.49
dez/17	1103.68	1095.85	29.56	29.56	873.63	2.61	2.61	37.39	37.39	1398.10	3.30	3.30
jan/18	1053.55	1031.08	24.37	24.37	593.73	2.26	2.26	46.84	46.84	2194.13	4.35	4.35
fev/18	1118.82	1114.10	23.68	23.68	560.92	2.07	2.07	28.40	28.40	806.83	2.49	2.49
mar/18	1180.77	1184.98	87.56	87.56	7666.05	6.90	6.90	83.35	83.35	6947.66	6.57	6.57
abr/18	1153.86	1162.22	9.52	9.52	90.68	0.82	0.82	1.16	1.16	1.34	0.10	0.10
mai/18	1134.82	1104.83	82.21	82.21	6758.32	6.75	6.75	112.20	112.20	12589.67	9.22	9.22
jun/18	1176.01	1172.30	39.26	39.26	1541.06	3.23	3.23	42.97	42.97	1846.85	3.54	3.54
jul/18	1085.06	1070.55	-91.28	91.28	8332.50	-9.19	9.19	-76.77	76.77	5893.23	-7.72	7.72
ago/18	1105.13	1098.95	-112.02	112.02	12547.99	-11.28	11.28	-105.84	105.84	11201.54	-10.66	10.66
set/18	1109.30	1069.78	-66.00	66.00	4356.32	-6.33	6.33	-26.48	26.48	700.97	-2.54	2.54
out/18	1089.94	1076.83	-209.54	209.54	43908.35	-23.80	23.80	-196.43	196.43	38586.26	-22.31	22.31
nov/18	1059.73	1024.48	-58.61	58.61	3435.64	-5.85	5.85	-23.37	23.37	546.15	-2.33	2.33

<b>Periodo</b>	<b>Y Polinomial aditivo</b>	<b>Y Polinomial Multiplicativ</b>	<b>Erro Aditivo</b>	<b>Modulo do erro aditivo</b>	<b>Erro Quadratico</b>	<b>Erro Percentual (%) Aditivo</b>	<b>Modulo do Erro Percentual (%) Aditivo</b>	<b>Erro Multiplicativ</b>	<b>Modulo Erro Multiplicativ</b>	<b>Erro Quadratico Multiplicativ</b>	<b>Erro Percentual (%) Multiplicativ</b>	<b>Modulo do Erro Percentual (%) Multiplicativ</b>
dez/18	1034.95	995.64	-100.25	100.25	10050.17	-10.73	10.73	-60.94	60.94	3713.67	-6.52	6.52
jan/19	978.39	931.32	-78.83	78.83	6214.31	-8.76	8.76	-31.77	31.77	1009.12	-3.53	3.53
fev/19	1037.07	1000.31	-12.58	12.58	158.28	-1.23	1.23	24.17	24.17	584.26	2.36	2.36
mar/19	1092.29	1057.48	-67.96	67.96	4618.57	-6.63	6.63	-33.15	33.15	1099.21	-3.24	3.24
abr/19	1058.49	1030.72	3.79	3.79	14.34	0.36	0.36	31.55	31.55	995.23	2.97	2.97
mai/19	1032.41	973.58	-71.85	71.85	5162.95	-7.48	7.48	-13.02	13.02	169.57	-1.36	1.36
jun/19	1066.41	1150.44	41.83	41.83	1749.63	3.77	3.77	-42.19	42.19	1780.25	-3.81	3.81
jul/19	1145.89	1169.78	23.90	23.90	571.10	2.04	2.04	0.00	0.00	0.00	0.00	0.00
ago/19	1158.46	1192.55	19.47	19.47	379.12	1.65	1.65	-14.62	14.62	213.86	-1.24	1.24
set/19	1154.99	1152.68	23.72	23.72	562.40	2.01	2.01	26.02	26.02	677.17	2.21	2.21
out/19	1127.84	1151.83	16.84	16.84	283.71	1.47	1.47	-7.15	7.15	51.16	-0.62	0.62
nov/19	1089.68	1087.60	11.84	11.84	140.19	1.07	1.07	13.91	13.91	193.61	1.26	1.26
dez/19	1056.80	1048.78	-20.03	20.03	401.18	-1.93	1.93	-12.01	12.01	144.20	-1.16	1.16

Apêndice M - Resultado dos indicadores de acurácia, da tendência polinomial corrigida, Error Médio (MAE), Erro Médio Quadrático (MSE), Erro Médio Percentual (MPE) e Erro Percentual Médio (MAPE)

<b>Acurácia Tendencia Polinomial</b>				
Tipo de decomposição	MAE	MSE	MPE	MAPE
Aditivo	31,77	2001,81	-0,74	3,67
Multiplicativo	30,49	1845,61	0,52	3,46

<b>Acurácia Tendencia Linear</b>				
Tipo de decomposição	MAE	MSE	MPE	MAPE
Aditivo	42,77	2701,07	-0,68	5,17
Multiplicativo	36,68	2110,32	-0,68	4,44

## Apêndice N - Cálculo da acurácia da tendência linear corrigida

Período	Y Linear aditivo	Y Linear Multiplicativo	Erro Aditivo	Modulo do erro aditivo	Erro Quadrático	Erro Percentual (%) Aditivo	Modulo do Erro Percentual (%) Aditivo	Erro Multiplicativo	Modulo Erro Multiplicativo	Erro Quadrático Multiplicativo	Erro Percentual (%) Multiplicativo	Modulo do Erro Percentual (%) Multiplicativo
jan/13	532.40	436.58	-67.78	67.78	4594.47	-14.59	14.59	28.03	28.03	785.94	6.03	6.03
fev/13	439.48	477.44	25.14	25.14	631.80	5.41	5.41	-12.83	12.83	164.49	-2.76	2.76
mar/13	506.31	514.07	-63.62	63.62	4047.71	-14.37	14.37	-71.39	71.39	5096.31	-16.13	16.13
abr/13	484.74	510.52	-42.06	42.06	1769.15	-9.50	9.50	-67.84	67.84	4601.80	-15.32	15.32
mai/13	471.57	491.50	45.72	45.72	2090.18	8.84	8.84	25.78	25.78	664.76	4.98	4.98
jun/13	519.14	528.31	-1.85	1.85	3.43	-0.36	0.36	-11.02	11.02	121.52	-2.13	2.13
jul/13	523.98	548.01	54.13	54.13	2930.03	9.36	9.36	30.10	30.10	906.09	5.21	5.21
ago/13	551.49	570.18	26.61	26.61	708.31	4.60	4.60	7.93	7.93	62.83	1.37	1.37
set/13	563.67	562.75	8.96	8.96	80.27	1.56	1.56	9.89	9.89	97.73	1.73	1.73
out/13	552.89	574.50	19.75	19.75	389.89	3.45	3.45	-1.87	1.87	3.49	-0.33	0.33
nov/13	531.83	554.51	-34.67	34.67	1202.34	-6.97	6.97	-57.36	57.36	3290.18	-11.54	11.54
dez/13	516.79	546.92	-18.64	18.64	347.55	-3.74	3.74	-48.77	48.77	2378.18	-9.79	9.79
jan/14	470.58	519.39	69.65	69.65	4850.81	12.89	12.89	20.84	20.84	434.31	3.86	3.86
fev/14	540.23	566.59	0.00	0.00	0.00	0.00	0.00	-26.36	26.36	694.91	-4.88	4.88
mar/14	607.05	608.59	40.20	40.20	1616.00	6.21	6.21	38.66	38.66	1494.94	5.97	5.97
abr/14	585.49	602.97	61.76	61.76	3814.28	9.54	9.54	44.29	44.29	1961.23	6.84	6.84
mai/14	572.32	579.18	26.82	26.82	719.33	4.48	4.48	19.95	19.95	398.10	3.33	3.33
jun/14	619.89	621.18	-20.75	20.75	430.58	-3.46	3.46	-22.04	22.04	485.75	-3.68	3.68
jul/14	787.29	768.94	-41.85	41.85	1751.03	-5.61	5.61	-23.49	23.49	552.00	-3.15	3.15
ago/14	814.81	798.37	-69.36	69.36	4810.93	-9.30	9.30	-52.93	52.93	2801.35	-7.10	7.10
set/14	826.99	786.35	1.96	1.96	3.85	0.24	0.24	42.60	42.60	1814.53	5.14	5.14
out/14	816.20	801.17	12.75	12.75	162.54	1.54	1.54	27.78	27.78	771.49	3.35	3.35
nov/14	795.14	771.80	-54.63	54.63	2984.25	-7.38	7.38	-31.28	31.28	978.72	-4.22	4.22
dez/14	780.11	759.78	-39.60	39.60	1567.85	-5.35	5.35	-19.27	19.27	371.45	-2.60	2.60
jan/15	571.33	602.20	44.60	44.60	1989.19	7.24	7.24	13.73	13.73	188.61	2.23	2.23
fev/15	640.98	655.74	7.22	7.22	52.17	1.11	1.11	-7.54	7.54	56.83	-1.16	1.16
mar/15	707.80	703.10	7.31	7.31	53.44	1.02	1.02	12.01	12.01	144.17	1.68	1.68

Periodo	Y Linear aditivo	Y Linear Multiplicativo	Erro Aditivo	Modulo do erro aditivo	Erro Quadratico	Erro Percentual (%) Aditivo	Modulo do Erro Percentual (%) Aditivo	Erro Multiplicativo	Modulo Erro Multiplicativo	Erro Quadratico Multiplicativo	Erro Percentual (%) Multiplicativo	Modulo do Erro Percentual (%) Multiplicativo
abr/15	686.24	695.41	63.69	63.69	4056.52	8.49	8.49	54.52	54.52	2972.21	7.27	7.27
mai/15	673.06	797.55	60.90	60.90	3708.37	8.30	8.30	-63.59	63.59	4043.61	-8.66	8.66
jun/15	720.63	853.97	66.56	66.56	4429.64	8.45	8.45	-66.78	66.78	4459.87	-8.48	8.48
jul/15	888.04	882.48	-48.76	48.76	2377.40	-5.81	5.81	-43.20	43.20	1866.38	-5.15	5.15
ago/15	915.55	914.83	-56.99	56.99	3248.33	-6.64	6.64	-56.27	56.27	3166.09	-6.55	6.55
set/15	765.17	752.26	53.25	53.25	2835.77	6.51	6.51	66.16	66.16	4377.71	8.08	8.08
out/15	916.95	915.26	-37.53	37.53	1408.33	-4.27	4.27	-35.84	35.84	1284.71	-4.08	4.08
nov/15	895.89	880.41	-70.13	70.13	4917.69	-8.49	8.49	-54.65	54.65	2986.82	-6.62	6.62
dez/15	880.85	865.47	-60.85	60.85	3703.21	-7.42	7.42	-45.47	45.47	2067.57	-5.55	5.55
jan/16	834.64	819.24	-1.96	1.96	3.85	-0.24	0.24	13.44	13.44	180.56	1.61	1.61
fev/16	904.29	890.86	-16.84	16.84	283.60	-1.90	1.90	-3.41	3.41	11.63	-0.38	0.38
mar/16	971.11	953.93	-50.33	50.33	2533.38	-5.47	5.47	-33.15	33.15	1098.76	-3.60	3.60
abr/16	786.99	787.86	48.96	48.96	2397.44	5.86	5.86	48.09	48.09	2312.84	5.75	5.75
mai/16	936.38	902.41	-33.50	33.50	1122.04	-3.71	3.71	0.47	0.47	0.22	0.05	0.05
jun/16	983.95	965.04	-86.56	86.56	7492.22	-9.65	9.65	-67.65	67.65	4575.99	-7.54	7.54
jul/16	988.79	996.02	-68.76	68.76	4727.35	-7.47	7.47	-75.99	75.99	5774.89	-8.26	8.26
ago/16	1016.30	1031.28	5.26	5.26	27.65	0.51	0.51	-9.72	9.72	94.52	-0.95	0.95
set/16	1028.48	1013.00	-30.15	30.15	909.10	-3.02	3.02	-14.67	14.67	215.17	-1.47	1.47
out/16	1017.69	1029.35	-4.89	4.89	23.96	-0.48	0.48	-16.55	16.55	273.96	-1.63	1.63
nov/16	996.63	989.03	-32.37	32.37	1048.04	-3.36	3.36	-24.77	24.77	613.47	-2.57	2.57
dez/16	981.60	971.16	22.02	22.02	484.83	2.19	2.19	32.46	32.46	1053.84	3.23	3.23
jan/17	935.39	918.28	-49.85	49.85	2485.03	-5.63	5.63	-32.74	32.74	1071.67	-3.70	3.70
fev/17	1005.04	997.48	21.11	21.11	445.73	2.06	2.06	28.67	28.67	822.09	2.79	2.79
mar/17	1071.86	1066.97	22.16	22.16	491.07	2.03	2.03	27.05	27.05	731.96	2.47	2.47
abr/17	1050.30	1052.82	30.09	30.09	905.44	2.79	2.79	27.57	27.57	760.25	2.55	2.55
mai/17	1037.12	1007.27	8.08	8.08	65.22	0.77	0.77	37.93	37.93	1438.40	3.63	3.63
jun/17	1084.69	1076.10	49.52	49.52	2451.76	4.37	4.37	58.11	58.11	3376.79	5.12	5.12
jul/17	1089.53	1109.56	32.58	32.58	1061.26	2.90	2.90	12.55	12.55	157.41	1.12	1.12
ago/17	1117.05	1147.74	41.09	41.09	1688.51	3.55	3.55	10.40	10.40	108.24	0.90	0.90
set/17	1129.23	1126.32	34.33	34.33	1178.66	2.95	2.95	37.24	37.24	1386.69	3.20	3.20

Periodo	Y Linear aditivo	Y Linear Multiplicativo	Erro Aditivo	Modulo do erro aditivo	Erro Quadratico	Erro Percentual (%) Aditivo	Modulo do Erro Percentual (%) Aditivo	Erro Multiplicativo	Modulo Erro Multiplicativo	Erro Quadratico Multiplicativo	Erro Percentual (%) Multiplicativo	Modulo do Erro Percentual (%) Multiplicativo
out/17	1118.44	1143.44	67.51	67.51	4557.32	5.69	5.69	42.51	42.51	1807.03	3.58	3.58
nov/17	1097.38	1097.64	101.52	101.52	10306.18	8.47	8.47	101.26	101.26	10252.64	8.45	8.45
dez/17	1082.35	1076.84	50.89	50.89	2589.95	4.49	4.49	56.40	56.40	3180.54	4.98	4.98
jan/18	1036.14	1017.31	41.78	41.78	1745.80	3.88	3.88	60.61	60.61	3673.56	5.62	5.62
fev/18	1105.78	1104.10	36.72	36.72	1347.99	3.21	3.21	38.40	38.40	1474.93	3.36	3.36
mar/18	1172.61	1180.00	95.72	95.72	9162.88	7.55	7.55	88.33	88.33	7801.70	6.96	6.96
abr/18	1151.05	1163.38	12.33	12.33	152.11	1.06	1.06	0.00	0.00	0.00	0.00	0.00
mai/18	1137.87	1112.14	79.16	79.16	6266.11	6.50	6.50	104.89	104.89	11002.78	8.62	8.62
jun/18	1185.44	1187.16	29.83	29.83	889.71	2.45	2.45	28.11	28.11	789.97	2.31	2.31
jul/18	1027.71	1022.69	-33.93	33.93	1151.53	-3.41	3.41	-28.91	28.91	835.68	-2.91	2.91
ago/18	1055.23	1057.04	-62.12	62.12	3858.86	-6.26	6.26	-63.93	63.93	4087.25	-6.44	6.44
set/18	1067.41	1036.52	-24.11	24.11	581.28	-2.31	2.31	6.78	6.78	45.99	0.65	0.65
out/18	1056.62	1051.47	-176.22	176.22	31054.67	-20.02	20.02	-171.07	171.07	29265.77	-19.43	19.43
nov/18	1035.56	1008.60	-34.45	34.45	1186.64	-3.44	3.44	-7.49	7.49	56.11	-0.75	0.75
dez/18	1020.53	988.76	-85.83	85.83	7366.73	-9.18	9.18	-54.06	54.06	2922.73	-5.78	5.78
jan/19	974.32	933.42	-74.76	74.76	5589.26	-8.31	8.31	-33.86	33.86	1146.76	-3.76	3.76
fev/19	1043.97	1012.33	-19.48	19.48	379.49	-1.90	1.90	12.16	12.16	147.85	1.19	1.19
mar/19	1110.79	1081.16	-86.46	86.46	7475.28	-8.44	8.44	-56.84	56.84	3230.30	-5.55	5.55
abr/19	1089.23	1065.20	-26.96	26.96	726.65	-2.54	2.54	-2.92	2.92	8.55	-0.28	0.28
mai/19	1076.05	1017.58	-115.50	115.50	13339.16	-12.02	12.02	-57.02	57.02	3251.85	-5.94	5.94
jun/19	1123.62	1085.50	-15.38	15.38	236.56	-1.39	1.39	22.74	22.74	517.18	2.05	2.05
jul/19	1128.46	1117.62	41.32	41.32	1707.49	3.53	3.53	52.16	52.16	2720.53	4.46	4.46
ago/19	1155.98	1154.41	21.95	21.95	481.94	1.86	1.86	23.52	23.52	553.02	2.00	2.00
set/19	1168.16	1131.27	10.55	10.55	111.28	0.89	0.89	47.43	47.43	2249.96	4.02	4.02
out/19	1157.37	1146.87	-12.69	12.69	161.01	-1.11	1.11	-2.19	2.19	4.78	-0.19	0.19
nov/19	1136.31	1099.42	-34.79	34.79	1210.39	-3.16	3.16	2.10	2.10	4.39	0.19	0.19
dez/19	1121.28	1077.13	-84.50	84.50	7140.75	-8.15	8.15	-40.36	40.36	1628.71	-3.89	3.89

Apêndice O - Resultado dos indicadores de acurácia da tendência linear corrigida Error Médio (MAE), Erro Médio Quadrático (MSE), Erro Médio Percentual (MPE) e Erro Percentual Médio (MAPE)

Mês	Volume Base Original	Média Movel Bimestral	Média Movel Timestral	Indicador Diferença 2 periodos	Indicador Diferença 3 periodos	Mês	Volume Base Original	Média Movel Bimestral	Média Movel Timestral	Indicador Diferença 2 periodos	Indicador Diferença 3 periodos
	A	B	C	A - B	A - C		A	B	C	A - B	A - C
jan/13	464.62					jan/14	540.23	497.65	522.65	42.58	17.59
fev/13	464.62					fev/14	540.23	519.19	511.84	21.04	28.39
mar/13	442.68	464.62		-21.94		mar/14	647.25	540.23	526.20	107.02	121.05
abr/13	442.68	453.65	457.31	-10.97	-14.62	abr/14	647.25	593.74	575.90	53.51	71.35
mai/13	517.29	442.68	450.00	74.60	67.29	mai/14	599.14	647.25	611.58	-48.12	-12.44
jun/13	517.29	479.99	467.55	37.30	49.74	jun/14	599.14	623.19	631.21	-24.06	-32.08
jul/13	578.11	517.29	492.42	60.82	85.69	jul/14	745.45	599.14	615.18	146.31	130.27
ago/13	578.11	547.70	537.56	30.41	40.55	ago/14	745.45	672.29	647.91	73.15	97.54
set/13	572.63	578.11	557.83	-5.47	14.80	set/14	828.95	745.45	696.68	83.50	132.27
out/13	572.63	575.37	576.28	-2.74	-3.65	out/14	828.95	787.20	773.28	41.75	55.67
nov/13	497.15	572.63	574.46	-75.48	-77.31	nov/14	740.51	828.95	801.12	-88.44	-60.60
dez/13	498.15	534.89	547.47	-36.74	-49.32	dez/14	740.51	784.73	799.47	-44.22	-58.96

Mês	Volume Base Original	Média Movel Bimestral	Média Movel Timestral	Indicador Diferença 2 periodos	Indicador Diferença 3 periodos	Mês	Volume Base Original	Média Movel Bimestral	Média Movel Timestral	Indicador Diferença 2 periodos	Indicador Diferença 3 periodos
	A	B	C	A - B	A - C		A	B	C	A - B	A - C
jan/15	615.93	740.51	769.99	-124.58	-154.06	jan/16	832.68	822.88	841.73	9.80	-9.05
fev/15	648.20	678.22	698.98	-30.02	-50.78	fev/16	887.45	826.34	826.15	61.11	61.30
mar/15	715.11	632.07	668.21	83.05	46.90	mar/16	920.78	860.07	846.71	60.71	74.07
abr/15	749.93	681.66	659.75	68.28	90.18	abr/16	835.95	904.12	880.30	-68.17	-44.35
mai/15	733.96	732.52	704.41	1.44	29.55	mai/16	902.88	878.37	881.39	24.52	21.49
jun/15	787.19	741.95	733.00	45.25	54.19	jun/16	897.39	869.42	886.54	27.98	10.85
jul/15	839.28	760.58	757.03	78.70	82.25	jul/16	920.03	900.14	878.74	19.90	41.29
ago/15	858.56	813.24	786.81	45.32	71.75	ago/16	1021.56	908.71	906.77	112.85	114.79
set/15	818.42	848.92	828.34	-30.50	-9.92	set/16	998.33	970.80	946.33	27.54	52.00
out/15	879.42	838.49	838.75	40.93	40.67	out/16	1012.80	1009.95	979.97	2.86	32.83
nov/15	825.76	848.92	852.13	-23.16	-26.37	nov/16	964.26	1005.57	1010.90	-41.31	-46.64
dez/15	820.00	852.59	841.20	-32.59	-21.20	dez/14	740.51	784.73	799.47	-44.22	-58.96



Mês	Volume Base Original	Média Movél Bimestral	Média Movél Timestral	Indicador Diferença 2 periodos	Indicador Diferença 3 periodos	Mês	Volume Base Original	Média Movél Bimestral	Média Movél Timestral	Indicador Diferença 2 periodos	Indicador Diferença 3 periodos
	A	B	C	A - B	A - C		A	B	C	A - B	A - C
jan/17	885.54	983.94	993.56	-98.40	-108.02	jan/18	1077.92	1166.07	1172.70	-88.15	-94.78
fev/17	1026.15	944.58	951.14	81.57	75.01	fev/18	1142.50	1105.58	1136.69	36.92	5.81
mar/17	1094.02	955.85	971.77	138.18	122.25	mar/18	1268.33	1110.21	1117.89	158.12	150.44
abr/17	1080.39	1060.09	1001.90	20.31	78.49	abr/18	1163.38	1205.42	1162.92	-42.03	0.46
mai/17	1045.20	1087.21	1066.85	-42.00	-21.65	mai/18	1217.03	1215.86	1191.40	1.17	25.63
jun/17	1134.21	1062.80	1073.20	71.42	61.01	jun/18	1215.27	1190.21	1216.25	25.07	-0.98
jul/17	1122.11	1089.71	1086.60	32.41	35.51	jul/18	993.78	1216.15	1198.56	-222.37	-204.78
ago/17	1158.14	1128.16	1100.51	29.98	57.63	ago/18	993.11	1104.53	1142.03	-111.42	-148.92
set/17	1163.56	1140.13	1138.15	23.43	25.41	set/18	1043.30	993.45	1067.39	49.86	-24.09
out/17	1185.95	1160.85	1147.94	25.10	38.01	out/18	880.40	1018.21	1010.06	-137.81	-129.66
nov/17	1198.90	1174.76	1169.22	24.15	29.68	nov/18	1001.11	961.85	972.27	39.26	28.84
dez/17	1133.24	1192.43	1182.80	-59.19	-49.56	dez/18	934.70	940.76	974.94	-6.06	-40.24

Mês	Volume Base Original	Média Movél Bimestral	Média Movél Timestral	Indicador Diferença 2 periodos	Indicador Diferença 3 periodos
	A	B	C	A - B	A - C
jan/19	899.56	967.91	938.74	-68.35	-39.18
fev/19	1024.49	917.13	945.12	107.36	79.36
mar/19	1024.33	962.02	952.91	62.31	71.41
abr/19	1062.27	1024.41	982.79	37.86	79.48
mai/19	960.56	1043.30	1037.03	-82.74	-76.47
jun/19	1108.24	1011.41	1015.72	96.83	92.52
jul/19	1169.78	1034.40	1043.69	135.38	126.09
ago/19	1177.93	1139.01	1079.53	38.92	98.40
set/19	1178.71	1173.86	1151.99	4.85	26.72
out/19	1144.68	1178.32	1175.47	-33.64	-30.79
nov/19	1101.52	1161.69	1167.11	-60.18	-65.59
dez/19	1036.77	1123.10	1141.64	-86.33	-104.86